



TAMPEREEN TEKNILLINEN YLIOPISTO  
TAMPERE UNIVERSITY OF TECHNOLOGY

ALEKSI ROIMA  
SÄHKÖASEMAN KYTKINLAITTEISTA KERÄTYN ANTURIDATAN  
HYÖDYNTÄMINEN ENNUSTAVASSA KUNNOSSAPIDOSSA

Diplomityö

Tarkastajat:  
Professori Nina Helander ja  
tutkijatohtori Jukka Huhtamäki

Tarkastaja ja aihe hyväksytty Talouden ja rakentamisen tiedekuntaneuvoston kokouksessa 27. elokuuta 2018

# TIIVISTELMÄ

**Aleksi Roima:** Sähköaseman kytkinlaitteista kerätyn anturidatan hyödyntäminen ennustavassa kunnossapidossa

Tampereen teknillinen yliopisto

Diplomityö, 92 sivua

Marraskuu 2018

Tietojohdamisen diplomi-insinöörin tutkinto-ohjelma

Pääaine: Informaatioanalytiikka

Tarkastajat: Professori Nina Helander ja tutkijatohtori Jukka Huhtamäki

**Avainsanat:** dataohjattu päätöksenteko, ennustava kunnossapito, IoT, kunnonvalvonta

Moderneilla teknologioilla, kuten esineiden internetiin (IoT) liittyvillä antureilla, langattomalla tiedonsiirrolla ja pilvipalveluiden laskentakapasiteetilla, voidaan mahdollistaa ennustava kunnossapito, jolla tunnistetaan vikatila jo ennen kuin se vaikuttaa systeemin toimintaan. Tällä voidaan saavuttaa merkittäviä kustannussäästöjä ja entistä luotettavampi toimintavarmuus. Tässä työssä käsitellään tapaustutkimuksena Fingrid Oyj:n kunnossapidon siirtymää kohti dataohjattua ennustavaa kunnossapitomallia.

Sähkön saantivarmuudella on merkittävä vaikutus koko Suomen kilpailukyvyille. Kriittisessä roolissa sähkönsiirrossa on kantaverkko, jota Fingrid kehittää ja ylläpitää. Fingridin vastuulla ovat esimerkiksi sähköasemien kytkinlaitteet, joiden tehtävänä on erottaa sähköverkon osat toisistaan ja ohjata energian kulkeutumista. Vuoden 2018 alussa Fingridillä siirryttiin uuteen kunnossapitomalliin, jossa huoltotarkastuksia tehdään aiempaa useammin koeohjausten avulla, ja näistä koeohjauksista kerätään dataa laitteiden toiminnasta.

Muutokseen liittyen käynnissä on pilottihanke, jossa kytkinlaitteiden komponentteja monitoroidaan IoT-antureilla. Tarkastelun kohteena ovat kytkinlaitteiden moottorit, katkaisijoiden iskunvaimentimet sekä erottimien ja maadoituskytkimien vaihteistot. Tässä työssä selvitettiin, miten IoT-anturoinnilla mahdollistetaan mekaanisten laitteiden kunnonvalvonta, ja mitä kunnossapidon siirtyessä dataohjattuun päätöksentekoon on huomioitava.

Tutkimuksessa löydettiin kirjallisuuskatsauksen ja Fingridin kunnossapidon asiantuntijoiden kanssa käytyjen keskustelujen perusteella laitteiden komponenttien kuntoa kuvaavia tunnuslukuja liittyen virtaprofiiliin, äänispektriin ja äänen värähtelysignaaliin. Empiirisenä aineistona toimi Fingridin sähköasemalta kerätty todellinen anturidata eli virta- ja äänisignaalit. Tutkimuksessa esitettiin tunnuslukujen määrittämiseen anturidatasta tarvittavaa matemaattista taustaa, signaalinkäsittelyn menetelmiä ja laskennassa käytettävät ohjelmakoodit sekä kuvaavat visualisoinnit python-ohjelmointikielen avulla.

Kunnossapidon siirtyessä dataohjattuun päätöksentekoon on tehdyn kirjallisuuskatsauksen perusteella huomioitava, ettei muutos ole pelkästään teknologinen. Analytiikasta on luotava iteratiivinen toiminto, joka vaikuttaa johtamistapaan, teknologiaan, henkilöstön osaamiseen, päätöksentekoprosesseihin ja organisaatiokulttuuriin. Tavoitteena on löytää tilanne, jossa syntyvät kustannukset ja saavutettava liiketoiminta-arvo ovat organisaatiolle optimaalisessa suhteessa.

## ABSTRACT

**Aleksi Roima:** Utilization of sensor data collected from substation switchgear in predictive maintenance

Tampere University of Technology

Master of Science Thesis, 92 pages

November 2018

Master's Degree Programme in Information and Knowledge Management

Major: Information analytics

Examiners: Professor Nina Helander and Postdoctoral researcher Jukka Huhtamäki

**Keywords:** condition monitoring, data-driven decision making, IoT, predictive maintenance

With modern technologies, such as internet of things (IoT) -sensors, wireless data transmission and cloud computing, performing predictive maintenance is easier than ever before. Visibility to mechanical components' wearing makes it possible to identify fault states even before they affect system's operations. This can lead to major cost savings and achieving better reliability of operations. In this research, we conduct a case study about Fingrid Oyj's maintenance transfer to data-driven predictive maintenance model.

The trustworthiness of electricity transfer is a remarkable factor for Finland's competitive capacity. At a crucial role in electricity transfer's point of view is the power transmission system, which is maintained and developed by Fingrid. Fingrid's responsibilities include for example substations' switchgears, which take care of protecting and controlling energy transfer. From the beginning of 2018, Fingrid changed to a new maintenance model, where maintenance checks are performed more often using test steering. Data about the devices operations are collected from these test sequences.

Related to this change, the company has started a pilot project, where switchgears' mechanical components are monitored using IoT-sensors. The monitoring is performed on switchgears' motors, circuit breakers' shock absorbers as well as disconnectors' and earthing disconnectors' gearing. This study investigates how IoT-sensors can make mechanical equipment's condition monitoring possible, and what needs to be taken into consideration when transferring maintenance to data-driven decision making.

In this research, using literature review and conversations with Fingrid's maintenance experts, we were able to identify figures of merits that describe machinery's condition. These figures of merits were related to the motor current signature, sound spectrum and sound vibration signals. Data from Fingrid's substations switchgear was used as an empirical material. This data was current and sound signals. The mathematical background and signal processing methods required for calculations are presented in the research. Figures of merits and visualizations describing them were conducted using programming language python.

According to the produced literature review, there are multiple things to consider on the transfer of maintenance model to data-driven decision making. The change isn't purely technological. Instead, it's an iterative function that affects leadership, technology, personnel competences, decision making processes and organisation culture. The goal is to find a situation where costs and achieved business value are in balance.

## ALKUSANAT

Aloittaessani yliopisto-opinnot syksyllä 2015 en ollut asettanut itselleni tavoitteita tai tarkalleen tiennyt mitä tulevan pitää. Olin päättänyt olla avoimena erilaisille mahdollisuuksille ja toimia kuten parhaaksi koen. Näin hieman yli 3 vuotta opintojen aloituksen jälkeen ja suurin osa tutkinnosta jo takana, on pakko todeta, että omaa jaksamista on tullut venytettyä äärimmilleen. Uudestaan en samaa tekisi, mutta silti en muuttaisi mitään.

Kuten montaa muutakin asiaa omien yliopisto-opintojeni pikamatkalla, tämänkin diplomityön aloitusta voi kutsua onnelliseksi sattumaksi, tai kuten ystäväni ovat todenneet, jälleen yhdeksi päähänpistoksi. Suunnitelmana ei ollut aloittaa lopputyön tekemistä näin aikaisessa vaiheessa, mutta tilaisuuden tarjouduttua, en kokenut kieltäytymistäkään vaihtoehtona. Lähdin hakemaan haastetta, enkä halunnut mennä siitä, mistä aita on matalimmillaan. Katsoen taaksepäin koko prosessia, voi tätä tavoitetta pitää saavutettuna.

Haluan kiittää ohjaajiani professori Nina Helanderia ja tutkijatohtori Jukka Huhtamäkeä suunnan löytämisestä, tuesta ja mielenkiintoisista keskusteluista. Kiitokset haluan osoittaa myös Fingridin ohjaajille Tuomas Laitiselle, Juhani Tammelle ja projektipäällikkö Taina Lylylle, jotka tarjosivat mielenkiintoisen ja haastavan aiheen sekä mahdollistavat työn toteutuksen.

Kiitän myös työnantajani Solitan projektitiimiä ja muita upeita työkavereita avusta ja kannustuksesta koko kirjoitusprosessin aikana. Erityiskiitokset ovat paikalleen Satu Tanolle, jolta ajatus diplomityön aiheesta sai alkunsa, Ville Tanskaselle, jonka kanssa käydyt keskustelut aiheen ympäriltä olivat suureksi avuksi, ja Heidi Sinkkoselle, joka jaksoi kysellä kuulumisia ja neuvoa olemaan itselle armollinen.

Lopuksi haluan vielä esittää kiitollisuuteni perheelleni, opiskelukavereille ja muille läheisille, joiden ansiosta oma jaksaminen on riittänyt tämänkin projektin loppuun viemisessä.

Tampereella 20.11.2018

Aleksi Roima

# SISÄLLYSLUETTELO

1.	JOHDANTO .....	1
1.1	Kohdeyritys .....	2
1.2	Tutkimuksen tausta .....	2
1.3	Tavoite ja tutkimuskysymykset.....	3
1.4	Rajoitukset.....	4
1.5	Rakenne.....	5
2.	TUTKIMUKSEN TOTEUTUS .....	6
2.1	Tutkimuksen viitekehys .....	6
2.1.1	Tieteenfilosofia .....	6
2.1.2	Lähestymistapa.....	7
2.1.3	Tutkimusmetodologia .....	8
2.1.4	Aikahorisontti.....	8
2.1.5	Aineistonkeruumenetelmä .....	9
2.2	Tutkimusprosessi.....	10
3.	KUNNOSSAPITO JA KYTKINLAITTEET .....	12
3.1	Kunnossapito.....	12
3.1.1	Reaktiivinen kunnossapito .....	13
3.1.2	Ehkäisevä kunnossapito .....	14
3.1.3	Ennustava kunnossapito .....	15
3.1.4	Proaktiivinen kunnossapito .....	17
3.2	Kytkinlaitteet .....	17
3.2.1	Katkaisijat .....	18
3.2.2	Katkaisijoiden vikatilat .....	20
3.2.3	Erottimet ja maadoituskytkimet.....	22
3.2.4	Erottimien ja maadoituskytkimien vikatilat.....	24
4.	DATAOHJATTU PÄÄTÖKSENTEKO .....	26
4.1	Dataohjatun päätöksenteon lähtökohdat.....	26
4.2	Analytiikan prosessimalli: CRISP-DM.....	28
4.3	Analytiikan prosessimalli: Visuaalinen analytiikka.....	31
4.4	Analytiikan tasot .....	33
5.	KYTKINLAITTEIDEN TUNNUSLUVUT .....	37
5.1	Katkaisijan, erottimen ja maadoituskytkimen moottorin tunnusluvut .....	37
5.2	Katkaisijan iskunvaimentimen tunnusluvut .....	43
5.3	Erottimen ja maadoituskytkimen vaihteiston tunnusluvut .....	44
5.4	Ohjausyksikön tunnusluvut .....	47
6.	TUNNUSLUKUIEN MÄÄRITYS.....	48
6.1	Katkaisijan moottorin virtasignaali .....	48
6.2	Katkaisijan moottorin äänisignaali.....	53
6.3	Katkaisijan iskunvaimentimen äänisignaali .....	58
6.4	Erottimen ja maadoituskytkimen moottorin virtasignaali .....	60

6.5	Erottimen ja maadoituskytkimen moottorin äänisignaali.....	63
6.6	Erottimen ja maadoituskytkimen vaihteiston äänisignaali.....	68
6.7	Ohjausyksikön tunnusluvut.....	72
7.	TULOKSET JA POHDINTA .....	74
7.1	Yhteenveto .....	74
7.2	Teoreettinen kontribuutio .....	77
7.3	Käytännön vaikutukset.....	79
7.4	Tutkimuksen arviointi ja yleistettävyyys .....	81
7.5	Jatkotutkimuskohteet.....	83
	LÄHTEET.....	85

## KUVALUETTELO

<b>Kuva 1.</b>	<i>Fingridin kunnonhallinnan IoT-arkkitehtuuri (Tammi 2018) .....</i>	<i>9</i>
<b>Kuva 2.</b>	<i>Kunnossapidon maturiteettitasot, mukaillen lähdettä Lee et al. (2008) .....</i>	<i>13</i>
<b>Kuva 3.</b>	<i>Esimerkki RCM-lähestymistavan kunnossapitomallista (mukaillen lähdettä Lakervi &amp; Partanen 2008) .....</i>	<i>16</i>
<b>Kuva 4.</b>	<i>ABB:n SF<sub>6</sub> kaasukatkaisijan keskeiset komponentit (mukaillen lähteitä Elovaara &amp; Haarla 2011; ABB 2013) .....</i>	<i>19</i>
<b>Kuva 5.</b>	<i>Siemensin 3DN3 saksityyppisen tartuntaerottimen keskeiset komponentit (mukaillen lähdettä Siemens 2018).....</i>	<i>23</i>
<b>Kuva 6.</b>	<i>CRISP-DM prosessimalli (suomennettu lähteestä Bosnjak et al. 2009).....</i>	<i>29</i>
<b>Kuva 7.</b>	<i>Visuaalisen analytiikan prosessimalli (suomennettu lähteestä Kohlhammer et al. 2011).....</i>	<i>32</i>
<b>Kuva 8.</b>	<i>Audiosignaalin analysointi (mukaillen lähdettä Glowacz 2016) .....</i>	<i>39</i>
<b>Kuva 9.</b>	<i>Katkaisijan kahden eri ohjauksen virtaprofiilit.....</i>	<i>49</i>
<b>Kuva 10.</b>	<i>Viritystajan määrittäminen virtapiikkien avulla.....</i>	<i>50</i>
<b>Kuva 11.</b>	<i>Virrankulutuksen laskeminen summaintegraalilla .....</i>	<i>51</i>
<b>Kuva 12.</b>	<i>Katkaisijan moottorin raakasignaali.....</i>	<i>53</i>
<b>Kuva 13.</b>	<i>Katkaisijan moottorin taajuusspektri kahdelle perättäiselle ikkunalle .....</i>	<i>54</i>
<b>Kuva 14.</b>	<i>Katkaisijan moottorin spektrogrammi.....</i>	<i>55</i>
<b>Kuva 15.</b>	<i>Spektrin keskipiste katkaisijan moottorin äänisignaaliille.....</i>	<i>56</i>
<b>Kuva 16.</b>	<i>Spektrin vinous katkaisijan moottorin äänisignaaliille .....</i>	<i>57</i>
<b>Kuva 17.</b>	<i>Spektrin nollanylitystaajuus katkaisijan moottorin äänisignaaliille .....</i>	<i>57</i>
<b>Kuva 18.</b>	<i>Katkaisijan moottorin kahden ohjauksen MFCC-arvoja .....</i>	<i>58</i>
<b>Kuva 19.</b>	<i>Yksittäisen katkaisijan ohjauksen MFCC-arvojen esiintymistiheydet.....</i>	<i>58</i>
<b>Kuva 20.</b>	<i>Iskunvaimentimen tunnusluvut esimerkkitalalle.....</i>	<i>60</i>
<b>Kuva 21.</b>	<i>Eroittimen ohjauksien virtaprofiileja .....</i>	<i>61</i>
<b>Kuva 22.</b>	<i>Maadoituskytkimen ohjauksien virtaprofiileja .....</i>	<i>61</i>
<b>Kuva 23.</b>	<i>Eroittimen ja maadoituskytkimen ohjauksien ohjaus-ajat ja virrankulutus.....</i>	<i>62</i>
<b>Kuva 24.</b>	<i>Eroittimen ja maadoituskytkimen moottorien raakasignaalit .....</i>	<i>63</i>
<b>Kuva 25.</b>	<i>Eroittimen ja maadoituskytkimen moottorien spektrogrammit .....</i>	<i>63</i>
<b>Kuva 26.</b>	<i>Eroittimen ja maadoituskytkimen moottorien spektrin keskipisteet .....</i>	<i>64</i>
<b>Kuva 27.</b>	<i>Eroittimen ja maadoituskytkimen moottorien spektrin vinoudet.....</i>	<i>65</i>
<b>Kuva 28.</b>	<i>Eroittimen ja maadoituskytkimen moottorien spektrin nollanylitystaajuudet .....</i>	<i>66</i>
<b>Kuva 29.</b>	<i>Eroittimen ja maadoituskytkimen MFCC-arvoja .....</i>	<i>67</i>
<b>Kuva 30.</b>	<i>Eroittimen ja maadoituskytkimen vaihteistojen raakasignaalit .....</i>	<i>68</i>

<b>Kuva 31.</b>	<i>Erottimen ja maadoituskytkimen vaihteiston prosessoitu raakasignaali.....</i>	<i>69</i>
<b>Kuva 32.</b>	<i>Erottimen vaihteiston tunnusluvut esimerkkitalalle .....</i>	<i>69</i>
<b>Kuva 33.</b>	<i>Maadoituskytkimen vaihteiston tunnusluvut esimerkkitalalle .....</i>	<i>70</i>
<b>Kuva 34.</b>	<i>Ohjausyksikön ilmankosteus- ja lämpötila-arvot .....</i>	<i>73</i>



## LYHENTEET JA MERKINNÄT

CBM	Kuntoperustainen kunnossapito (engl. <i>Condition Based Maintenance</i> )
CRISP-DM	Toimialariippumaton tiedonlouhinnan prosessimalli (engl. <i>Cross-industry standard process for data mining</i> )
FFT	Jatkuva integraalimuunnos (engl. <i>Fast Fourier Transform</i> )
IoT	Esineiden internet (engl. <i>Internet of Things</i> )
MFCC	MFC-kertoimet (engl. <i>Mel Frequency Cepstral Coefficients</i> )
RCM	Luotettavuuskeskeinen kunnossapito (engl. <i>Reliability Centered Maintenance</i> )
RMS	Tehollisarvo (engl. <i>Root Mean Square</i> )
$A$	amplitudi
$d$	vertailusignaali
$f$	taajuus
$i$	datapiste
$I$	virta
$n$	taajuuskomponentti
$N$	lukumäärä
$q$	varaus
$r$	jäännössignaali
$s$	signaali
$t$	aika

# 1. JOHDANTO

Sähkön saantivarmuudella on valtavat vaikutukset koko Suomen yhteiskunnalle. Maan kattava sähkön suurhäiriö kustantaisi Suomessa jopa 100 miljoonaa euroa tunnissa (Satuli 2018). Suomalainen sähkönsiirto on maailman kärkitasoa, ja se kasvaa Suomelle jatkuvasti entistä suuremmaksi kilpailuvaltiksi myös kansainvälisten yritysten investointien kannalta (Satuli 2018; Sihvonen-Punkka 2018). Keskeinen osa sähköverkon toimivuutta ovat siitä löytyvät komponentit ja niiden luotettavuus. Suomen kantaverkkoyhtiön Fingrid Oyj:n (myöhemmin Fingrid) sähköverkossa vuoteen 2007 mennessä kirjatuista vioista jopa yli 63 % liittyi katkaisijoihin tai erottimiin eli toisin sanoen kytkinlaitteisiin (Kuosa 2007). Kaikki näistä vioista eivät johtaneet häiriöihin, mutta lisäsivät riskiä kantaverkon toimintavarmuudessa. Tässä tutkimuksessa selvitetään Fingridin kytkinlaitteiden kunnossapitomallin siirtymisen edellytyksiä korkeamman arvontuotannon tasoille, jonka avulla voidaan mahdollistaa entistä parempi toimintavarmuus ja luotettavuus sähkönsiirrolle.

Verrattuna perinteisiin, usein aikaperustaisiin, kunnossapitomalleihin moderneilla teknologioilla kuten dataa keräävillä sensoreilla, langattomalla tiedonsiirrolla ja pilvipalveluiden laskentateholla voidaan mahdollistaa kustannustehokas ja toimintavarmuutta parantava laitteiden ylläpito (Parpala & Iacob 2017). Ennustavaa kunnossapittoa hyödyntävät organisaatiot voivat paremmin varautua muutoksiin, maksimoida komponenttien käyttöpotentiaalia ja minimoida huoltokatkojen aiheuttamia haittoja (Lakervi & Partanen 2008). Laitteiden toimintaan liittyvän datan kerääminen ja analysointi mahdollistavat päätöksentekoprosessien kehittämisen pois yksittäisen päättäjän intuitiosta kohti dataohjattua ja perustellumpaa päätöksentekoa (Golightly et al. 2017). Potentiaalisista hyödyistä huolimatta muutos ei ole helppo, vaan se edellyttää sitoutumista niin yksilö- kuin organisaatitasollakin. Fingridiin liittyvän tapaustutkimuksen lisäksi tässä työssä perehdytään dataohjattuun päätöksentekoon ja edellytyksiin, joita IoT (engl. *Internet of Things*) -analytiikan mahdollistamaan kunnossapitomallin siirtymään liittyy.

Gubbin et al. (2013) mukaan IoT:lla tarkoitetaan laitteiden kykyä jakaa tietoa eri alustoille yhteisessä ekosysteemissä. Tämä onnistuu anturoinnilla, data-analytiikalla ja tiedon visualisoinnilla, jotka mahdollistetaan pilvipalveluiden tarjoamalla viitekehyksillä (Gubbi et al. 2013). Käytännön läheisesti IoT:lla viitataan usein internet-verkon laajenemiseen fyysisiin laitteisiin, jonka avulla mahdollistetaan datan kerääminen ja jakaminen verkon muille toimijoille (International Telecommunication Union 2012). Suomenkielisessä kirjallisuudessa IoT:sta käytetään myös sekaisin nimityksiä esineiden internet ja teollinen internet, vaikka näillä onkin sävyeroja. Tässä työssä IoT:lla tarkoitetaan anturointia ja laitteiden liittämistä ekosysteemiin, jonka avulla mahdollistetaan datan keruu ja nopea

analysointi. IoT-datalla puolestaan viitataan tässä tutkimuksessa IoT-anturoinnilla kerättyyn dataan, johon tehtävät analyysit pohjautuvat.

## 1.1 Kohdeyritys

Tämä työ toteutettiin tapaustutkimuksena osana Solita Oy:n toimittamaa analytiikkaprojektia suomalaiselle kantaverkkoyhtiö Fingrid Oyj:lle. Fingrid on vastuussa sähkön jakelusta Suomen kantaverkossa, jossa sähköä siirretään voimalaitoksista alueellisiin jakeluverkkoihin ja teollisuudelle. Yrityksen asiakkaiksi luetaan verkkoyhtiöt, sähkön suurkuluttajat, sähköntuottajat ja muut sähkömarkkinatoimijat. (Fingrid Oyj 2018a.) Näiden lisäksi yrityksen toiminta näkyy myös kotitalouksille sähkön siirron luotettavuudessa. Tämä on myös yksi sen toiminnan keskeisimmistä mittareista, ja vuonna 2017 sähkön siirron toimintavarmuus olikin maailman kärkitasoa: jopa 99,99997 % (Sihvonen-Punkka 2018). Fingridin suurimpana omistajana on Suomen valtio, mutta sen omistusosuus on alle 30% (Fingrid Oyj 2018b). Haarla & Elovaara (2011) korostavat tämän olevan poikkeuksellinen tilanne, sillä muut pohjoismaiset kantaverkkoyhtiöt ovat täysin valtion omistamia toimijoita. Yrityksen luonnollinen monopoliasema ei kuitenkaan tarkoita, etteikö organisaatiolla olisi jatkuvaa tarvetta ja halua kehittyä. Satuli (2018) nostaa esille, että pienetkin häiriötilanteet toiminnassa tulevat erittäin kalliiksi, vaikuttaen koko Suomen yhteiskuntaan ja kilpailutilanteeseen.

Fingridin toimintaympäristö on suuren muutoksen kynnyksellä, sillä sähköntuotanto on siirtymässä entistä enemmän säätilariippuvaisiin voimalähteisiin kuten aurinko- ja tuulienergiaan. Tämä edellyttää toimia, ja muutosta edistääkseen vuonna 2018 yrityksellä on käynnissä kolme merkittävää digitaalisiin palveluihin sekä niiden mahdollistamaan arvonluontiin liittyvää kehityshanketta: datahub, sähkömarkkinoiden tulevaisuus ja älyverkot (Fingrid Oyj n.d.). Fingridin (n.d.) mukaan hankkeiden tarkoituksena on mahdollistaa entistä ympäristöystävällisempi sähköntuotanto ja parantaa toimintavarmuutta. Sähköverkon toimintavarmuuteen vaikuttaa merkittävästi Fingridin omien kantaverkon osana olevien laitteiden toimintakyky.

## 1.2 Tutkimuksen tausta

Vuoteen 2018 asti Fingridin sähköasemien kytkinlaitteiden kunnossapito on perustunut aikaperustaiseen huoltoon, jossa tarkastusmittauksia on suoritettu noin 10 vuoden välein tai vaihtoehtoisesti tarpeen vaatiessa vikatilanteessa. Aikaperustaisten mittausten jälkeen kunnossapito on ollut kuntooperustaista eli perustunut tarkasteltavien komponenttien kuntoon. Toimintamallilla yksittäinen keskeytys on kestänyt noin yhden päivän ja vaatinut keskeytyksen sähkönsiirtoon. (Laitinen & Tammi 2018; Tammi 2018.) Tämänlainen kunnossapito ei kuitenkaan ole tehokasta, sillä komponentin kunto ei aina heikkene samassa suhteessa käyttöiän kanssa, eikä vikatilanteita onnistuta täten etukäteen tunnistamaan. Ai-

kaperustainen tarkastelu aiheuttaa myös merkittävät määrät ylimääräistä työtä, sillä kytkinasemalla joudutaan vierailemaan paikan päällä tarkastamassa tilannetta, vaikka mitään muutostöitä ei lopulta suoritettaisikaan. Kunnossapitoyksikön tavoitetilana voidaan nähdä kunnossapito, jossa toimia tehdään yksittäisten komponenttien kunnon perusteella ennen kuin vikatilanteita pääsee tapahtumaan. Tällainen ennustava kunnossapitomalli edellyttää kuitenkin tulevien vikojen tunnistamista jo ennen niiden vaikuttamista systeemin toimintaan.

Vuoden 2018 alussa Fingridillä siirryttiin uuteen ylläpitomalliin, jossa kytkinlaitteiden toimintaa tarkastellaan koeohjausten avustuksella. Tämän myötä laitteisiin liittyvät huoltotarkastukset lisääntyvät noin nelinkertaisesti aiempaan ylläpitomalliin verrattuna. (Tammi 2018.) Pidemmän aikavälin tavoitteena voidaan nähdä tila, jossa mahdollinen alkava vika havaitaan arkipäiväisessä toiminnassa. Tämän tyyppisen kuntooperustaisen kunnossapidon mahdollistamiselle on Fingridillä otettu jo ensimmäiset askeleet, sillä pilottihankkeena toimivalle Kymin sähköasemalle on vuoden 2017 lopussa asennettu noin 360 verkkoon kytkettyä sensoria keräämään laitteiston toimintaan liittyvää informaatiota. Nämä IoT-anturit tuottavat dataa asemalla vallitsevista olosuhteista ja tehtävistä kytkenöistä. (Tammi 2018.) Tavoitteena on, että kyseisen informaation avulla pystyttäisiin tunnistamaan vikatilanteita ennen niiden tapahtumista. Koska kyseessä on vielä alkuvaiheessa oleva hanke, on tässä kohtaa olennaista tarkastella, mitä laitteiston kuntoon liittyviä parametreja kerättävästä datasta voidaan määrittää.

### 1.3 Tavoite ja tutkimuskysymykset

Tässä tutkimuksessa tarkastellaan tapaustutkimuksena Fingridin Kymin sähköasemalla IoT-pilottihankkeena toimivan anturoinnin sopivuutta tunnistaa ennalta vikatilanteita sähköasemien kytkinlaitteista kerätyn anturidatan perusteella. Tutkimuksessa keskitytään kytkinlaitteisiin: katkaisijoihin, erottimiin ja maadoituskytkimiin, sillä nämä ovat laitteita, joista dataa asemalla kerätään. Mekaaniset komponentit, joihin tutkimus keskittyy, ovat katkaisijan, erottimen ja maadoituskytkimen moottori, erottimen ja maadoituskytkimen vaihteisto sekä katkaisijan iskunvaimennin. Tämän lisäksi datalähteenä käsitellään ohjausyksikön olosuhteita eli lämpötilaa ja ilmankosteutta. Tapaustutkimuksen lisäksi tutkimuksessa tunnistetaan, mitä kunnossapidon siirtymisessä dataohjattuun päätöksentekoon tulee huomioida.

Olennaisten, kirjallisuuden perusteella tapahtuvan, tunnuslukujen tunnistamisen jälkeen, niitä johdetaan Fingridin Kymin sähköasemalta kerätystä data-aineistosta. Tällä hetkellä saatavilla olevaa dataa ovat mm. lämpötila, ilmankosteus, moottorin virtasignaali ja mekaanisten komponenttien läheltä nauhoitettu äänidata. Kirjallisuuden pohjalta tunnistettujen tunnuslukujen määrittämiseen tallennetusta raakasignaalista vaadittavat funktiot ja algoritmit esitetään ohjelmointikieli pythonin avulla. Näiden laskentaan liittyvä matemaattinen tausta ja tarvittavat signaalinkäsittelyn menetelmät käsitellään osana tutkimusta.

Diplomityön päätutkimuskysymys on seuraava:

- Miten IoT-anturoinnilla voidaan mahdollistaa mekaanisten laitteiden ennustava kuntooperustainen kunnossapito, ja mitä kunnossapidon siirtyessä dataohjattuun päätöksentekoon on otettava huomioon?

Tätä tukevia alatutkimuskysymyksiä puolestaan ovat:

- Mitä laitteiden kuntoa kuvaavia tunnuslukuja katkaisijoihin, maadoituskytkimiin ja erottimiin liittyy, joita voidaan tunnistaa Fingrid Oyj:n Kymin sähköaseman IoT-mittaroinnista?
- Miten edellä tunnistettuja tunnuslukuja voidaan tuottaa kytkinasemalta kerätystä data-aineistosta?

Työn alatutkimuskysymykset käsittelevät selkeästi tapaustutkimuksen tarkastelun kohteena olevan Fingridin toimintaa. Tutkimuksen empiirisissä osioissa ei oteta kantaa dataohjattuun päätöksentekoon liittyvään kunnossapidon siirtymään, vaan sitä esitellään taustateoriassa ja myöhemmin verrataan alatutkimuskysymyksissä saavutettuihin tuloksiin pohdinnassa. Tämän takia asetetut alatutkimuskysymykset eivät ota kantaa päätutkimuskysymyksen jälkimmäiseen osioon, joka käsittelee dataohjattua päätöksentekoa. Päätutkimuskysymyksessä huomioidaan kunnossapitomallin siirtymää edelleen Fingridin näkökulmasta, mutta tarkastelua ei rajata pelkästään tähän. Tämän takia tutkimuksen tuloksissa ei rajauduta ainoastaan Fingridin tilanteeseen, vaan sähköasemien kytkinlaitteiden kunnossapito toimii esimerkkitapauksena. Tutkimuksen pohjalta voidaan löytää apua myös toisessa valtiossa toimivan vastaavan kantaverkkoyhtiön tai toisenlaisella toimialalla tapahtuvaan kunnossapidon IoT-anturointiin tai dataohjattuun päätöksentekoon siirtymässä.

## 1.4 Rajoitukset

Tutkimuksessa rajataan tarkastelu Fingridin Kymin kytkinlaitteiden kunnonvalvontaan liittyvään mittaustilanteeseen tunnuslukujen osalta. Rajautuminen ainoastaan Kymin kytkinasemalta laskettaviin tunnuslukuihin johtuu käytettävissä olevasta empiirisestä aineistosta. Osana tutkimusta esitetään ohjelmakoodit, joiden avulla tunnusluvut saadaan mitattua raakadatasta laskettua. Näiden validointi onnistuu ainoastaan todellisen datan avulla, joten tämän takia myös tarkastelu rajataan koskemaan Kymin aseman mittaustilannetta. Päätutkimuskysymyksessä mainitun dataohjatun päätöksenteon osalta tarkastelua tehdään erityisesti liittyen Fingridin kunnossapidon asiantuntijoiden toimintaympäristössä tapahtuvaan päätöksentekoon. Tämän lisäksi tutkimuksessa tunnistetaan myös yleisemmällä tasolla kunnossapitomallin siirtymässä dataohjattuun päätöksentekoon vaikuttavia tekijöitä.

Tunnuslukujen osalta tutkimuksen tavoitteena on määrittää mahdollisia tunnuslukuja, joiden avulla voidaan arvioida laitteen kuntoa. Tutkimuksessa ei oteta kantaa tunnuslukujen hyvyyteen eli siihen, mitkä esitellyistä tunnusluvuista ovat parhaita laitteen kunnon kuvaamiseen. Tämä rajataan pois tutkimuksen piiristä kahdesta syystä: Tunnuslukujen hyvyyden määrittäminen vaatisi merkittävän määrän tutkimustyötä, joka kasvattaisi tämän tutkimuksen laajuutta tarpeettoman suureksi. Toiseksi, hyvyyden määrittäminen edellyttäisi joko todella suurta datamäärää ja tämän prosessointia, tai vaihtoehtoisesti dataa epäkuntoisista laitteista. Aikana, jolloin anturointia on Kymin sähköasemalta tehty, eivät kytkinlaitteet ole olleet epäkunnossa, joten luokittelussa olisi käytettävissä vain yhtä luokittelukategoriaa kuvaavaa aineistoa.

## 1.5 Rakenne

Työn ensimmäisessä luvussa, eli tässä johdantoluvussa, on esitetty tutkimukseen liittyvä tausta, kohdeyritys ja tutkimusongelma. Toisessa luvussa käsitellään tutkimusmenetelmää ja –metodologiaa sekä esitellään näkökulmien valintaa ja näiden vaikutusta itse tutkimukseen. Osana toista lukua esitellään tutkimuksessa käytettyä aineistoa sekä tutkimusprosessia. Tutkimuksen teoriatausta jakautuu kahteen osaan: kolmas luku käsittelee kunnossapitoa ja kytkinlaitteita sekä neljäs luku puolestaan dataohjattua päätöksentekoa. Kunnossapidon osalta pyritään luomaan käsitys, mistä on kyse ja miten eri kunnossapitomallit toimivat. Sähköasemien kytkinlaitteiden toimintalogiikan avaamisella mahdollistetaan koko ilmiön ymmärtäminen, jolloin tunnuslukuja on helpompi yhdistää fysikaalisiin reaali maailman ilmiöihin. Kytkinlaitteista esitellään niiden rooli sähköverkossa, rakenne ja yleisimmät vikatilat. Toisessa teoriakokonaisuudessa esitellään yleisesti dataohjattua päätöksentekoa, kaksi analytiikan prosessimallia: CRISP-DM sekä visuaalinen analytiikka ja analytiikan tasot syventyen IoT-analytiikan tasoihin. Teoriakokonaisuuden tarkoituksena on selittää ja nostaa esille erityispiirteitä muutoksesta, joita dataohjattuun kunnossapitomalliin siirtyminen edellyttää.

Viidennessä luvussa määritetään kirjallisuuden perusteella katkaisijoille, maadoituskytkimille ja erottimille keskeisiä Kymin kytkinlaitteiden kuntoon liittyvästä mittaustilanteesta saatavia tunnuslukuja. Kuudennessa luvussa selvitetään Fingridin data-aineistoon pohjautuen, miten tunnusluvut ovat määritettävissä nykyisillä datalähteillä. Luvussa esitellään ohjelmakoodit, joilla tunnusluvut on mahdollista saada määritettyä kerätystä raakasisignaalista. Seitsemännessä luvussa kuvataan tarkemmin tutkimuksen tulokset, niihin liittyvää pohdintaa ja mietitään tutkimuksen yleistettävyyttä sekä jatkotutkimuskohteita.

## 2. TUTKIMUKSEN TOTEUTUS

Tässä luvussa käsitellään tutkimuksessa käytettyä tutkimusmenetelmää ja valittua viitekehystä sekä kuvataan tutkimuksen toteutusta. Tieteellinen viitekehys esitellään Saundersin et al. (2009) sipulimallin (*engl. research onion*) avulla. Luvussa esitellään tutkimuksen viitekehystä varten tehtyjä valintoja ja niiden perusteluja sipulimallin tasojen mukaan. Tämän lisäksi esitellään käytetty aineisto sekä tutkimusprosessi.

### 2.1 Tutkimuksen viitekehys

Saundersin et al. (2009) sipulimalli koostuu kerroksista, joita tutkimuksen strategiaa pohdittaessa on läpikäytävä. Tehtävissä valinnoissa lähdetään liikkeelle uloimmasta kerroksesta ja edetään yksi kerrallaan sisimpään kerrokseen asti. Jokainen kerros on edeltävää kerrosta yksityiskohtaisempi ja täten tarkentaa hiljalleen tutkimuksen suuntaa. Sipulimallin kerrokset ovat seuraavat uloimmasta (epätarkimmasta) sisimpään (yksityiskohtaisimpaan): tieteenfilosofia, tutkimusote, tutkimusmetodologia, valinnat, aikahorisontti ja aineistonkeruumenetelmä. (Saunders et al. 2009.) Vaikka malli onkin tarkoitettu ensisijaisesti liiketoimintaan ja liikkeenjohtoon liittyvään tutkimukseen, sopii se käsillä olevaan tutkimukseen, sillä tutkimuksen tavoitteena on liiketoiminnan edistäminen datapohjaisen kunnossapitomallin avulla. Tutkimuksen merkittävä matemaattinen ja tietotekninen osuus kuitenkin vaikuttavat siihen, että kaikista kerroksista ei ole tunnistettavissa selkeää yksittäistä valintaa, vaan valinta voi koostua useammista suuntauksista tai se voidaan jättää tekemättä.

#### 2.1.1 Tieteenfilosofia

Saunders et al. (2009) korostavat tieteenfilosofian valinnan merkitystä koko tutkimuksen strategian kannalta. Omaksuttu tieteenfilosofia sisältää olettamuksia, joiden perusteella ympäröivää toimintaympäristöä tarkastellaan, ja tätä kautta tehdyillä valinnoilla on vaikutus koko tutkimukseen (Saunders et al. 2009; Bryman 2012). Saunders et al. (2009) jakavat tutkimusfilosofiat kahteen pääsuuntaukseen: ontologiaan ja epistemologiaan. Ontologiassa paneudutaan ihmisten tekemiin olettamuksiin ympäröivästä maailmasta ja tutkimuksesta eli tutkitaan todellisuuden luonnetta. Epistemologia puolestaan keskittyy tietoon ja siihen, milloin tieto on tietyllä tieteenalalla hyväksyttävää. (Saunders et al. 2009.) Epistemologian keskeisiä kysymyksiä ovat: Mitä tietoa on? Mitkä ovat tiedon rajat? Mistä tieto on peräisin ja milloin se on luotettavaa? (Wenning 2009.) Tämän tutkimuksen voidaan tunnistaa olevan epistemologinen tutkimus, sillä tutkimus ei keskity ihmisten tekemiin tulkintoihin, vaan ennemminkin tiedon hyväksyttävyyteen ja oikean tiedon tunnistamiseen.

Toinen tapa Saundersin et al. (2009) mukaan tieteenfilosofioiden lajitteluun on jakaa ne kolmeen kategoriaan: positivismiin, tieteelliseen realismiin ja interpretivismiin, jotka eroavat niin ontologian kuin epistemologian suhteen. Positivismissa kuvataan tapahtuneita tosiasioita ja jätetään huomiotta pohdinnan tuloksena syntyneet tai epävarmat oletukset. Positivismissa kohteet ovat jo valmiiksi tai ne saatetaan strukturoituun muotoon, jonka takia sitä käytetäänkin usein luonnontieteellisessä tutkimuksessa, kuten fysiikassa ja biologiassa. (Olkkonen 1993; Saunders et al. 2009.) Tieteellisen realismin mukaan havaittavat ja mitattavat asiat ovat valideja ja mahdollistavat pohjan tutkimukselle, mutta ilmiö tulee ymmärtää kontekstin avulla (Saunders et al. 2009). Interpretivismi korostaa ihmisten merkitystä ja roolia. Ajatuksen mukaan ihmiset ovat sosiaalisia toimijoita, jonka takia tutkimuksessa pitää ymmärtää ihmisen toimintaa. (Saunders et al. 2009.)

Osana tätä tutkimusta pyritään selvittämään mekaanisten komponenttien toiminnan kannalta keskeisiä tunnuslukuja. Tutkimusaineistona käytetään sähköasemien kytkinlaitteiden tilasta ja käytöstä syntyvää dataa. Ihmisen merkitys on tutkimusasetelmassa hyvin vähäinen, joka vaikuttaa keskeisesti tutkimusfilosofian valintaan. Tutkimuksen filosofia osuu pitkälti positivistiseen tutkimukseen. Valintaa tukee Saundersin et al. (2009) korostamat positivismille tyypilliset aineiston kvantitatiivisuus ja kattavuus. Tämän lisäksi tutkimuksesta voidaan tunnistaa myös joitain tieteelliseen realismiin liittyviä osia, sillä datalle annetaan kontekstia tutkimusasetelmassa olevista laitteistoista ja tämän avulla ymmärretään ilmiötä paremmin. Tieteelliseen realismiin liittyy myös päätutkimuskysymys, jossa pohditaan kunnossapidon siirtymää dataohjattuun päätöksentekoon vaikuttavia tekijöitä.

## 2.1.2 Lähestymistapa

Toisena kerroksena sipulimallissa määritetään tutkimuksen lähestymistapa. Lähestymistavat voidaan jakaa kahteen luokkaan: deduktiiviseen ja induktiiviseen järjestykseen (Saunders et al. 2009). Deduktiivinen järjely on luonnontieteille tyypillinen lähestymistapa, jossa lait ja määritelmät antavat pohjan tapahtumien ja havaintojen selitykselle hypoteesien muodossa (Collis & Hussey 2003; Saunders et al. 2009). Deduktiivinen päättely siis lähtee liikkeelle teoriasta, josta edetään havaintoihin. Induktiivinen järjely puolestaan tarkastelee yksittäistä spesifissä kontekstissa olevaa havaintokokonaisuutta, josta pyritään muodostamaan yleistettävissä olevaa teoriaa (Saunders et al. 2009). Toisin sanoen induktiivinen järjely aloittaa havainnoista ja etenee niiden pohjalta luotavaan teoriaan.

Tässä tutkimuksessa pyritään selvittämään kirjallisuuden sekä asiantuntijakeskusteluiden pohjalta keskeisiä tunnuslukuja tiettyjen komponenttien toiminnassa, ja tämän jälkeen paikallistamaan tunnuslukuja kvantitatiivisesta data-aineistosta. Kyseessä on siis deduktiivinen tutkimus, joka lähtee liikkeelle teorian kasaamisesta ja ymmärtämisestä. Kirjallisuusselvityksen pohjalta tunnistetaan tarkasteltavia kohteita, joita ohjelmakoodin avulla lasketaan tutkimusaineistosta.



### 2.1.3 Tutkimusmetodologia

Saundersin et al. (2009) sipulimallin kolmantena kerroksena määritetään sopiva tutkimusmetodologia. Metodologiaa valittaessa on huomioitava sen sopivuus asetettuihin tutkimuskysymyksiin (Saunders et al. 2009). Tämä tutkimus on metodologialtaan tapaustutkimus. Tapaustutkimuksessa tutkitaan kyseisellä tutkimuksen ajanhetkellä tapahtuvaa ilmiötä tietyssä ennalta määritellyssä kontekstissa (Benbasat et al. 1987; Yin 2003; Runeson & Höst 2009). Yin (2003) korostaa, että tapaustutkimuksessa ilmiötä ja kontekstia ei aina pysty selkeästi erottamaan toisistaan. Runeson & Höst (2009) korostavat tapaustutkimuksessa olevan paljon samoja piirteitä ja yhteneväisyyksiä survey-tutkimuksen, kokeellisen tutkimuksen ja toimintatutkimuksen kanssa.

Tapaustutkimuksia voidaan jaotella kahden dimension perusteella: yhden (engl. *single-case*) tai usean (engl. *multiple case*) tapauksen tarkastelu ja vaihtoehtoisesti holististen (engl. *holistic case*) tai upotettujen (engl. *embedded case*) tapauksien tutkiminen (Yin 2003; Saunders et al. 2009). Vain yksittäisen tapahtuman tai tilanteen tarkastelu vaatii Yinin (2003) mukaan vahvat perustelut, sillä tällaisessa tapauksessa tuloksilla ei ole selkeää vertailukohdetta, eikä niitä voida helposti yleistää. Fingridin anturidatan kerääminen kytkinasemalta toimii pilottihankkeena ennustavalle kunnossapidolle, joten tässä tutkimuksessa yksittäisen tapauksen tarkastelu on perusteltua, sillä aineisto on uniikkia eikä vertailukohdetta vielä ole saatavilla. Toisen dimension suhteen kyseessä on holistinen tapaustutkimus, sillä tapausta tarkastellaan puhtaasti Fingridin kunnossapitoyksikön näkökulmasta.

Saaranen-Kauppinen et al. (2009) korostavat tapaustutkimuksen aiheuttavan rajoituksia tulosten yleistettävyyteen ja edustavuuteen. Tarkoituksena ei ole luoda yleistettävää tietoa, vaan lisätä ymmärrystä tietyssä kontekstissa tapahtuvasta ilmiöstä. Tulosten arvioinnissa on kuitenkin syytä pohtia, rajautuvatko havaitut perusteet ja ilmiöt ainoastaan käsiteltyyn kontekstiin. Huolellinen tutkimus voi tarkkaan rajatussakin ympäristössä tarjota yksittäistilanteen ylittävää tulosta, mutta tämä vaatii tarkkaa tutkimustyötä. (Saaranen-Kauppinen et al. 2009.) Tätä tutkimusta tehdään lähtökohtaisesti parantamaan Fingridin ymmärrystä kuntoperustaisen kunnossapidon mahdollisuuksista ja keinoista, mutta tuloksia on syytä arvioida myös niiden yleistettävyydessä muille kytkinasemille ja mahdollisesti myös muiden valtioiden vastaaville toimijoille.

### 2.1.4 Aikahorisontti

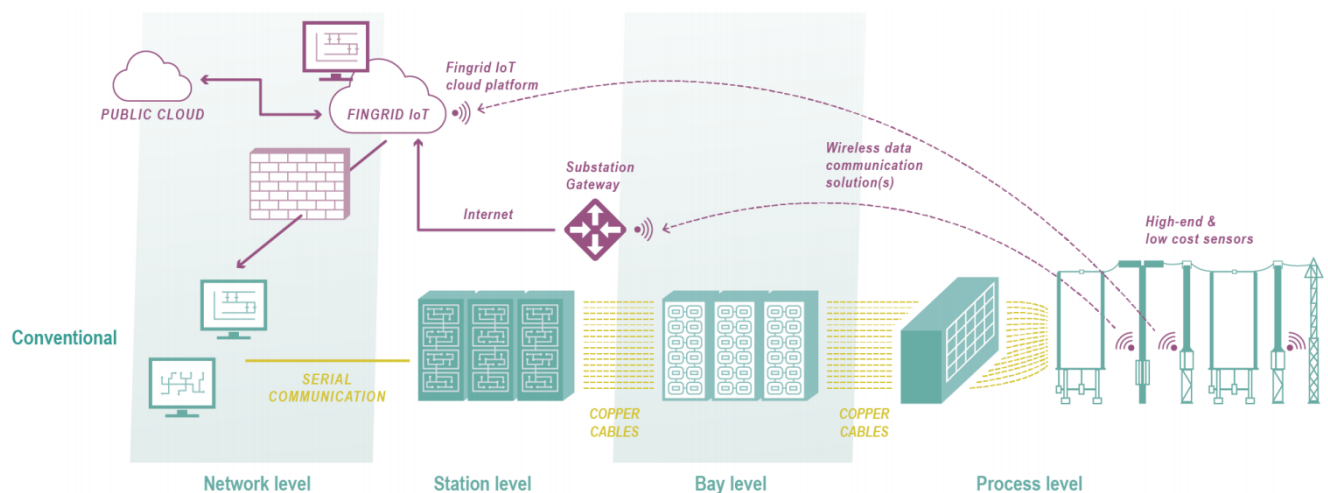
Saundersin et al. (2009) sipulimallin neljäntenä kerroksena on tutkimuksen aikahorisontti. Aikahorisontit voidaan jakaa pitkäaikaistutkimukseen (engl. *longitudinal studies*) sekä poikittaistutkimukseen (engl. *cross-sectional studies*). Pitkäaikaistutkimuksessa seurataan tutkimuskohdetta määritetyllä aikavälillä ja pyritään tunnistamaan esimerkiksi muutoksia käyttäytymisessä. Poikittaistutkimuksessa puolestaan tarkastellaan tutkimuskohdetta tietyllä ajanhetkellä. Tutkimuksen intressit eivät ole niinkään muutoksessa, vaan

ilmiöiden ymmärtämisessä tietyllä ajanhetkellä. (Saunders et al. 2009.) Tässä tutkimuksessa on kyse poikittaistutkimuksesta, sillä kunnossapidon anturidatan hyödynnettävyyttä ei tutkita muutoksena, vaan ennemminkin tämän hetkisen tilanteen selvityksenä. Käytettävä data ei kuitenkaan ole yksittäiseltä ajanhetkeltä, vaan sitä on kerätty jo pidemmän aikaa. Tästä huolimatta tutkimuksessa ei tarkastella datassa tapahtuvia muutoksia, vaan selvitetään tunnuslukuja, joita yksittäisistä mittauksista voidaan laskea.

### 2.1.5 Aineistonkeruumenetelmä

Tutkimuksessa käytettävän kirjallisuuden lisäksi aineisto pohjautuu pitkälti kvantitatiiviseen kytkinlaitteista kerättyyn dataan. Tunnuslukujen tunnistamisessa lähdemateriaalina hyödynnetään alan tutkimuksen lisäksi Fingridin asiantuntijoiden kanssa käytyjä keskusteluja ja niiden pohjalta kerättyä tietämystä aihepiiristä. Tämä nähdään työn kannalta tarpeelliseksi, sillä käsiteltävästä aihepiiristä on vain vähän tutkimusta, ja Fingridin kytkinlaitoksen mittausasetelma on uniikki. Näiden keskustelujen merkitys tutkimuksen kannalta on kuitenkin melko vähäinen, joten kyseistä aineistonkeruumenetelmää ei sen tarkemmin avata tässä yhteydessä. Tunnuslukujen selvittämisen jälkeen loppututkimus keskittyy vahvasti data-aineiston analysointiin.

Tutkimuksessa käytettävä data-aineisto on Fingridin keräämää anturidataa kytkinasemilta. Data lähetetään kytkinasemien sensoreista IoT-anturiyksikön langattomalla tiedonsiirrolla kytkinkentän reitittimeen ja siitä eteenpäin pilvipalveluun, josta dataa voidaan suoraan lukea ja suorittaa analyyskejä. Fingridin kunnonhallinnan IoT-arkkitehtuuri on esitetty kuvassa 1.



**Kuva 1.** Fingridin kunnonhallinnan IoT-arkkitehtuuri (Tammi 2018)

Kytkinasemalla antureilla sekä mikrofoneilla mitataan katkaisijoiden, maadoituskytkimien ja erottimien toimintaa. Kaikkien kolmen tyyppisen kytkinlaitteen toimintaa mittaavat anturit sijaitsevat niille omissa ohjausyksiköissä. Ohjausyksiköiden ulkopuolella ovat

ainoastaan ilmamikrofonit, jotka tallentavat ohjauslaatikon ulkopuolella kuuluvia ääniä. Taulukossa 1 on avattu dataa mittaavat anturit, niiden sijainti ja mitä niillä mitataan.

Anturin sijainti	Mittari	Mitattava asia
Erotin, erottimen ohjausyksikkö	2 ilmamikrofonia	Toiminnasta syntyvät mekaaniset sekä valokaaren äänet
	2 kontaktimikrofonia	Moottorin ja vaihteiston äänet
	Virtamittari	Moottorin virtaprofiili
	Lämpötilamittari	Ohjausyksikön lämpötila
	Ilmankosteusmittari	Ohjausyksikön ilmankosteus
Katkaisija, katkaisijan ohjausyksikkö	2 kontaktimikrofonia	Moottorin ja iskunvaimentimen toimintaan liittyvät äänet
	Ilmamikrofoni	Ohjausyksikön sisäiset, toiminnasta syntyvät äänet
	Virtamittari	Moottorin virtaprofiili
	Lämpötilamittari	Ohjausyksikön lämpötila
	Ilmankosteusmittari	Ohjausyksikön ilmankosteus
Maadoituskytkin, maadoituskytkimen ohjausyksikkö	2 kontaktimikrofonia	Toiminnasta syntyvät mekaaniset äänet
	Virtamittari	Moottorin virtaprofiili
	Lämpötilamittari	Ohjausyksikön lämpötila
	Ilmankosteusmittari	Ohjausyksikön ilmankosteus

**Taulukko 1.** *Kymin asemalle asennetut mikrofonit ja anturit*

Kymin aseman pilottivaiheessa anturit ja mikrofonit on asennettu kaikkiin 110 kV verkkoon liittyviin kytkinlaitteisiin. Tällaisia antureilla varustettuja kytkinlaitteita on seuraavat määrät: katkaisijoita 7 kappaletta, maadoituskytkimiä 26 kappaletta, kiertoerottimia 21 kappaletta ja tartuntaerottimia 7 kappaletta. Yhteensä tämä tarkoittaa 61 anturiyksikköä, sillä jokainen tartuntaerotin edellyttää 2 anturiyksikköä. Dataa kerääviä antureita ja mikrofoneja on Kymin asemalla yhteensä 361 kappaletta.

## 2.2 Tutkimusprosessi

Tutkimus lähti liikkeelle deduktiiviselle tutkimukselle tyypillisesti hyvin teorialähtöisesti. Teoria-aineiston avulla koottiin ensin tarvittava ymmärrys toimialasta ja kunnossapidon aihepiiristä, jotta tutkimuksen toteuttamiseksi saavutettiin käsiteltävästä ongelmasta vaadittava ymmärrystaso. Lisäksi taustateoriassa tutkittiin dataohjattua päätöksentekoa, jotta Fingridillä tapahtuva kunnossapitomallin muutos saadaan asetettua oikeanlaiseen kontekstiin analytiikan näkökulmasta. Taustateorian jälkeen komponenteille ominaisia tunnuslukuja selvitettiin aiheeseen liittyvän kirjallisuuden perusteella rajaten tarkastelu nyt Fingridin Kymin aseman mittausasetelmaan. Aineiston keräämisen jälkeen tulokset koottiin yhteen ja näistä määritettiin laskettavat tunnusluvut erikseen tarkasteltaville komponenteille. Tässä vaiheessa tunnistetut tunnusluvut ja niiden järjestyminen analysoitiin yhdessä Fingridin asiantuntijoiden kanssa, jonka myötä muutamia tunnuslukuja myös lisättiin seuraavassa vaiheessa laskettaviksi.

Aiemmassa vaiheessa tunnistetut tunnusluvut määritettiin python-ohjelmakoodin avulla ja näiden perusteella saatuja laskennallisia arvoja visualisoitiin esimerkkeinä käytettävälle otoksille. Tavoitteena ei ollut laskea tunnuslukuja koko aineistolle, vaan määrittää tapa, jolla laskeminen onnistuu. Tutkimuksen viimeisessä vaiheessa saatuja tuloksia analysoitiin ja pohdittiin, miten saavutetut tulokset rinnastuvat aiempiin teoriakokonaisuuksiin ja Fingridin tavoitteisiin. Samassa vaiheessa esitettiin myös yleisemmällä tasolla huomioita kunnossapitomallin siirtymästä kohti dataohjattua päätöksentekoa. Lopussa huomioitiin näkemyksiä jatkotutkimuskohteista ja tämän tutkimuksen rajoitteista.

### 3. KUNNOSSAPITO JA KYTKINLAITTEET

Tässä luvussa esitellään työn taustalla olevaa toimintaympäristöä ja kontekstia, jotta myöhemmissä luvuissa esiteltävien tarkastelukohteiden asettaminen fyysisen maailman tilanteisiin onnistuu helpommin. Tutkimuksen tarkastelussa on Fingridin kunnossapitomallin siirtymä, joten luvun ensimmäisessä osassa esitellään kunnossapidon teoriaa sekä kunnossapidon maturiteettitasot. Luvun toinen osa keskittyy kytkinlaitteisiin, joille tutkimuksessa määritetään mekaanisia tunnuslukuja. Kytkinlaitteista esitellään katkaisijat, erottimet ja maadoituskytkimet, näiden toimintaa sekä vikatilat.


#### 3.1 Kunnossapito

Pintelon & Parodi-Herz (2008) esittävät alalla vallitsevan käsityksen mukaan kunnossapidon tarkoittavan toimia, joilla fyysisiä omaisuuksia voidaan ylläpitää toimivassa kunnossa tai palauttaa toimivaan tilaan. Tähän he lisäävät kyseessä olevan laitteiden ja komponenttien saatavuuden ja luotettavuuden maksimointia (Pintelon & Parodi-Herz 2008). Pham & Wang (1996) puolestaan korostavat, että kunnossapito sisältää sekä suunniteltuja että suunnittelemattomia toimia, joita tehdään systeemien ylläpitoa ja palauttamista varten. He nostavat esille myös kustannusaspektin toteamalla, että kunnossapidon avulla pyritään saavuttamaan optimaalinen taso luotettavuuden ja turvallisuuden välillä minimaalilla kustannuksella (Pham & Wang 1996). Kunnossapidon vaatimukset riippuvat voimakkaasti laitteen tai kohteen käyttötarkoituksesta, esimerkiksi lentokoneissa tai sairaalajärjestelmissä viat on löydettävä ennen niiden tapahtumista, sillä muuten seuraukset voivat olla kohtalokkaita (Pham 1995; Pham & Wang 1996). Vastaava tilanne on myös Fingridin laitteistossa, sillä kantaverkossa tapahtuvilla vikatilanteilla voi olla merkittävät yhteiskunnalliset seuraukset (Satuli 2018).

Suomen kielisessä kirjallisuudessa kunnossapito ja huolto termejä käytetään usein sekaisin keskenään. Alastalo et al. (n.d.) huomauttavat, etteivät käsitteet ole Suomessa vakiintuneita. Käsitteiden merkitykset vaihtelevat eri toimialoilla huomattavasti. Termit tarkoittavat kuitenkin eri asiaa: Huollolla tarkoitetaan konkreettisia toimenpiteitä, joilla varmistetaan koneiden ja laitteiden toiminta. Kunnossapito puolestaan on laajempi kattotermi, joka pitää sisällään huollon lisäksi aiheeseen liittyvän ajattelutavan ja abstrakteja osatekijöitä. (Alastalo et al. n.d.) Kunnossapito-termin laajuus on nähtävillä Järviö et al. (2007) viittaamasta Suomen standarditoimiston (SFS EN-13306 2010) määritelmästä, joka määrittelee kunnossapidon koostuvan kaikista kohteeseen liittyvistä liikkeenjohdollisista, hallinnollisista ja teknisistä toimenpiteistä, joilla kohteen kunto säilyy sellaisella tasolla, että sen avulla voidaan suorittaa vaadittu toiminto. Kunnossapidon yläpuolella kirjallisuudessa käytetään usein termiä kunnonhallinta (engl. *maintenance management*), jonka voidaan määrittää tarkoittavan yleisemmällä tasolla kaikkia toimenpiteitä, joiden avulla

nykyomaisuuden kuntoa ja sen kehittymistä hallitaan ja johdetaan (Fingrid Oyj 2011; Aro et al. 2015). Tässä työssä käytetään suomenkielistä termiä kunnossapito, sillä vaikka asiaa tarkastellaankin teknisestä komponenttinäkökulmasta, edellyttää kunnossapidon kehittäminen myös organisatorisia muutoksia.

Kunnossapidon tekniikat voidaan jakaa Lee et al. (2008) mukaan teknologisen maturiteetin mukaan kuudelle eri tasolle. Korkeampi taso tarkoittaa parempaa toiminta-aikaa eli luotettavuutta. Kunnossapidon maturiteettitasoja on havainnollistettu kuvassa 2. Kuvasta 2 on jätetty huomiotta Lee et al. (2008) esittämät tasot: ei kunnossapitoa (alin maturiteettitaso) ja kunnossapitoa vaatimattomat/ itseään kunnostavat laitteet (ylin maturiteettitaso), sillä ne eivät ole tässä tutkimuksessa relevantteja.



**Kuva 2.** Kunnossapidon maturiteettitasot, mukaillen lähdettä Lee et al. (2008)

Wang (2002) huomauttaa, että kunnossapidon maturiteettitasoista on tärkeää huomioida, että harvan organisaation kunnossapidon taso muistuttaa suoraan tiettyä tasoa tai noudattaa kaikkia sen periaatteita. Usein käytettävät kunnossapitomallit yhdistelevät tai ovat mukaelmia kuvassa 2 esitetyistä tasoista.

### 3.1.1 Reaktiivinen kunnossapito

Reaktiivisella kunnossapidolla (engl. *reactive maintenance*) tarkoitetaan Lee et al. (2008) mukaan huoltotoimintaa, jota monet mieltävät perinteiseksi huolloksi: laite tai komponentti korjataan tai korvataan sen rikkouduttua. Reaktiivinen kunnossapito tunnetaan myös tulipalojen sammuttamisena eli ongelmaan puututaan vasta sen ilmennyttyä kutsuamalla paikalle huollosta vastaavat tahot. Tämän tyyppisen kunnossapidon määrä vähentyy jatkuvasti, sillä turvallisuus- sekä ympäristövaatimukset ja toimialoilla käytävä kilpailu ovat pakottaneet laitteiden toiminta-ajat vastaamaan korkeisiin vaatimuksiin. Reak-

tiivinen kunnossapito voi kuitenkin edelleen olla kustannussyistä perusteltua tietyssä kontekstissa, mikäli koneen hajoaminen ei aiheuta merkittävää haittaa arkiseen toimintaan. (Lee et al. 2008; Aro et al. 2015.)

Järviö et al. (2007) ovat suomentaneet standardissa SFS EN-13306 (2010) käytetyn termin korjaavaksi kunnossapidoksi (engl. *corrective maintenance*). Standardissa (Järviö et al. 2007; SFS EN-13306 2010) tämä määritellään kunnossapidoksi, jossa toimintakunto palautetaan sen jälkeen, kun vikaantuminen onnistutaan havaitsemaan. Tämän voidaan tulkita tarkoittavan samaa kunnossapitolajia kuin Lee et al. (2008) reaktiivinen kunnossapito. Aro et al. (2015) korostavat, että menneisyydessä sähkölaitteiden kohdalla ainoana kunnossapitomallina vallitsi reaktiivinen kunnossapito, sillä huoltotoimia ei osattu mitenkään ennakoida.

### 3.1.2 Ehkäisevä kunnossapito

Ehkäisevässä kunnossapidossa (engl. *preventive maintenance*) laitteen osia uusitaan tai huolletaan tietyin ennalta päätettyjen, joko säännöllisten tai sopeutuvien, aikavälien mukaan (Badía et al. 2002; Lee et al. 2008; Aro et al. 2015). Wang (2002) korostaa, ettei huoltotoimenpiteessä välitetä komponentin sen hetkisestä kunnosta tai aiemmasta vika-historiasta, vaan kunnossapitoa tehdään puhtaasti aikaperustaisesti. Ehkäisevä kunnossapito perustuu usein aiemmin kerättyyn informaatioon laitteiden ja komponenttien vikaantumishistoriasta. Rikkoontumistietojen perusteella voidaan määrittää laskennallinen arvo komponentin elinkaarelle ja ehkäisevän kunnossapidon ideologian mukaan korvata tai korjata komponentti ennen kuin tämä laskennallinen arvo saavutetaan. (Lee et al. 2008.) Pham et al. (1997) lisäävät, että huoltovälinä käytettävä laskennallinen arvo tulee sovitaa tehtävään toimintaan ja se voi olla esimerkiksi todennettu komponentin lyhin kesto ennen rikkoutumista tai keskimääräinen elinkaari. Aro et al. (2015) kertovat sähkötekniikan historian pohjalta, että siirryttäessä reaktiivisesta kunnossapidosta ehkäisevään kunnossapitoon olivat aluksi kaikkien sähköasemien laitteiden huoltovälit samat. Myöhemmin opittiin tunnistamaan laiteryhmäkohtaisia huoltoaikavälejä, jolloin siirryttiin lähemmäs kuntoperustaista ehkäisevää huoltoa (Aro et al. 2015).


Järviö et al. (2007) listaavat ehkäisevään kunnossapitoon liittyvän esimerkiksi: kunnonvalvonnan, testaamisen, käynninvalvonnan, määräystenmukaisuuden toteamisen ja vikaantumistietojen analysoinnin. Ehkäisevän kunnossapidon suurimpana heikkoutena ovat sen taloudelliset kustannukset. Huollettavia kohteita ei vaihdeta perustuen niiden todelliseen kuntoon, vaan annettuihin aikasykleihin. Tämä tarkoittaa, että vielä täysin toimivat ja hyväkuntoiset komponentit saatetaan vaihtaa, vaikka niillä olisikin vielä elinkaarta jäljellä. (Lee et al. 2008.) Ehkäisevä kunnossapito ei myöskään takaa laitteen toimivuutta, sillä laitteet saattavat hajota ennen määritettyä huoltosykliä. Tämän takia laitteelle optimaalisen huoltosyklin määrittäminen korostuu sekä kustannusten että toimintavarmuuden kannalta. Erityisesti ennalta tuntemattomille laitteille huoltosyklin määrittäminen on hankala tehtävä.

### 3.1.3 Ennustava kunnossapito

Ennustavassa kunnossapidossa (engl. *predictive maintenance*) on kyse kunnossapitostrategiasta, jossa laitetta tai komponenttia huolletaan tarpeen mukaan sellaisena hetkenä, kun jokin tietty kuntoa mittaava indikaattori saavuttaa ennalta määritellyn raja-arvon (Lee et al. 2008). Ennustava kunnossapitomalli edellyttää dataa laitteiden toiminnasta tai tilasta, joten sitä tulee mitata joko tietyin väliajoin tai jatkuvasti (Barbera et al. 1996; Lee et al. 2008). Lee et al. (2008) korostavat, että ennustavan kunnossapidon implementoiminen osaksi liiketoimintaa edellyttää sekä teknistä kyvykkyyttä että osaavaa henkilökuntaa. Teknologian on mahdollistettava laitteen tai komponentin tilaa kuvaavan datan kerääminen, mutta päätöksenteko siitä, tuleeko toimenpiteisiin ryhtyä, jää henkilöstölle, jonka tulee ymmärtää vikaantumisen vaikutukset (Lee et al. 2008).

Ennustava kunnossapito on tutkimuksen kannalta olennaisin kunnossapitofilosofia, joten sitä on syytä tarkastella tarkemmin. Kothamasu et al. (2006) jakavat ennustavan kunnossapidon lajit kahteen kategoriaan: luotettavuuskeskeiseen kunnossapitoon (engl. *reliability centered maintenance*, myöhemmin RCM) ja kuntooperustaiseen kunnossapitoon (engl. *condition based maintenance*, myöhemmin CBM). RCM:ssä on kyse lähestymistavasta, jossa hyödynnetään tarkasteltavasta kohteesta tehtäviä luotettavuusarvioita, joiden avulla luodaan kustannustehokas huoltoaikataulu. Lähestymistapa koostuu kahdesta tehtävästä: Ensimmäisessä häiriötilat kategorisoidaan ja analysoidaan niiden aiheuttamien vaikutusten perusteella. Toisessa tehtävässä edellä määritetyille kategorioille arvioidaan niiden tapahtumisesta aiheutuvat vaikutukset tarkasteltavan kohteen toimintaan. (Kothamasu et al. 2006.) Rao (1996) tarkentaa arvioitavien vaikutusten olevan useimmiten liittyen organisaation toimintaan, talouteen tai ympäristöön sekä turvallisuuteen. Näiden vaiheiden jälkeen luodaan oma päätöksentekologiikka, jonka avulla määritetään kunnossapidolle optimaalinen aikataulu. RCM:n mukaan parhainta mahdollista aikataulua etsitään muuttamalla suunnitelmaa käytöstä syntyvän kohteen luotettavuustietojen perusteella. (Kothamasu et al. 2006.) Esimerkki RCM:n mukaisesta kunnossapitomallista on nähtävillä kuvassa 3.





**Kuva 3.** Esimerkki RCM-lähestymistavan kunnossapitomallista (mukaillen lähdettä Lakervi & Partanen 2008)

Käsitteet eivät tehdyn kirjallisuusselvityksen perusteella vaikuta olevan täysin yksiselitteisiä ja yhtenäisiä aihepiirissä. Esimerkiksi Lakervi & Partanen (2008) puhuvat ehkäisvästä kunnossapidosta (engl. *reliability based maintenance*) yläkäsitteenä kuntoon tai aikaan perustuville kunnossapitotyypeille. Kirjoittajien tarjoamasta määritelmistä on kuitenkin tunnistettavissa sen olevan hyvin yhtenäinen Kothamasun et al. (2006) RCM termin kanssa. Vaikka toisiaan muistuttavien käsitteiden määritelmät ovatkin melko yhteneviä, ei käsitteiden välillä ole huomattavissa selkeää hierarkiaa eli esimerkiksi yleistä mielipidettä siitä, mitkä ovat yläkäsitteitä tietyn tyyppisille kunnossapitomalleille.

Kothamasun et al. (2006) mukaan CBM on lähestymistapa, jossa päätöksenteko perustuu tarkasteltavan laitteen tai sen komponenttien kuntoon. CBM edellyttää jatkuvasti tai tasaisin aikavälein saatavilla olevaa kvantitatiivista dataa, joka kuvaa laitteen hetkittäistä kuntoa. Lähestymistapaan liittyy keskeisesti oletus siitä, että tietyn laitteen toiminta seuraa samanlaista elinkaarta. (Kothamasu et al. 2006.) Tämä tarkoittaa, että laitteen huollon jälkeen voidaan sen kuntoa verrata aiemmin kerättyyn aineistoon sen toiminnasta. Lakervi & Partanen (2008) antavat esimerkkinä sähköverkon jakeluverkot, joiden kunnossapidon perustana ovat pitkällä aikavälillä tietokantoihin kerätyt kuntotiedot ja niiden pohjalta luodut ikääntymismallit. Näiden perusteella voidaan kunnossapitotoimia tehdä ennen vikatilanteiden tapahtumista oikeaan aikaan ja oikeassa paikassa tarpeen vaatiessa.

Kothamasu et al. (2006) nostavat esille, että CBM:n heikkoutena voidaan nähdä alkukustannukset, sillä se edellyttää laitteiston ja toimivan monitoroinnin asentamista tutkittavaan kohteeseen. Vahvuutena puolestaan on kyky havaita vikatilanteet ennen niiden tapahtumista. Lähestymistavan myötä tulevasta mitattavuudesta voi olla myös merkittäviä hyötyjä vikojen lähteiden paikallistamiseen. (Kothamasu et al. 2006.)

Sähköverkosta puhuttaessa on huomioitava, että vaikka ehkäisevällä ja ennustavalla kunnossapidolla voidaan estää monia vikatilanteita, on reaktiivisella kunnossapidolla edelleen pysyvä tarve. Kaikkiin vikatilanteisiin ei ole mahdollista varautua, tai niitä voi olla mahdotonta ennustaa. Esimerkiksi luonnonilmiöistä johtuvat vauriot, kuten ukkosen aiheuttamat, säilyvät edelleen reaktiivisen kunnossapidon piirissä. (Lakervi & Partanen 2008; Laitinen & Tammi 2018.)

### 3.1.4 Proaktiivinen kunnossapito

Proaktiivinen kunnossapito (engl. *proactive maintenance*) on Lee et al. (2008) mukaan melko tuore kunnossapitostrategia, jonka tavoitteena on luoda mahdollisimman tarkka ymmärrys virheisiin johtavista syy-seuraussuhteista. Filosofia on Lee et al. (2008) matriteettitasoissa ylimpänä tarkoittaen korkeinta koneiden toimintavarmuutta. Ideologian keskiössä on päätöksenteko, jota tukee kerätty digitaalinen informaatio moderneilla teknologioilla. Laitteen toimintakunnon tulisi esittää trendiä, eikä hetkellistä tilannetta. Strategian keskiössä on tiedon levittäminen ja ajatus siitä, ettei yksittäisen vikatilanteen selvitys auta korjaamaan vain yksittäistä tuotantolaitetta, vaan laajemmalla tasolla parantamaan koko tuotantoketjua, esimerkiksi vaikuttaen aina laitteiston kehitykseen ja valmistukseen saakka. (Lee et al. 2008.)

Proaktiivinen kunnossapito rakentuu Lee et al. (2008) mukaan kolmen keskeisen ajatuksen ympärille: Ensinnäkin vikojen ratkaisusta tulisi siirtyä vikojen ennakoimiseen. Tämä mahdollistuu keskittymällä ongelmien juurisyihin, eikä pelkästään näkyvien ongelmien ratkaisuun. Toisena keskeisenä ajatuksena proaktiivisessa kunnossapidossa huoltoinformaation pitäisi palautua takaisin koneelle, valmistajalle ja käyttöprosessiin. Kehitystä tulee tehdä koko tuotteen elinkaareissa. Kolmantena ajatuksena Lee et al. (2008) esittävät, että älykästä informaatioteknologiaa tulee hyödyntää tuotteiden ja systeemien seuraamiseen, ennustamiseen ja suorituskyvyn optimoimiseen.

## 3.2 Kytkinlaitteet

Sähköasema on sähköenergian jakelu- tai siirtoverkon kohta, josta käsin mahdollistetaan jännitteen muunto, suoritetaan kytkentöjä, jaetaan tai keskitetään sähköenergian siirtoa eri johdoille (Elovaara & Haarla 2011). Sähköasemien keskeisiä laitteita ovat erilaiset muuntajat sekä kytkinlaitteina tunnetut katkaisijat, erottimet ja maadoituskytkimet. Tässä luvussa esitetään katkaisijoiden, erottimien ja maadoituskytkimien rooli sähköverkossa, niiden mekaaninen rakenne sekä vikatilat.

Kytkinlaitteiden merkitys sähköverkossa voidaan Elovaara & Haarlan (2011) mukaan jakaa kolmeen tehtävään:

- Erottaa tarpeen vaatiessa sähköverkon eri osat toisistaan.
- Muuttaa tarvittaessa verkon topologiaa, eli osien järjestystä, ja tämän avulla ohjata energian kulkeutumista sähköverkossa.
- Vikatilanteessa erottaa viallinen osa pikaisesti muusta sähköverkosta vaaratilanteiden sekä vahinkojen välttämiseksi.

Kytkinlaitteille on ominaista kaksi erillistä tilaa: toimintatila ja normaalitila. Toimintatilassa kytkinlaitteen tulee muuntua eristeestä johtavaksi kappaleeksi tai vaihtoehtoisesti päinvastoin riippuen siitä minkä suuntainen ohjaus on kyseessä. Normaalitilassa puolestaan kytkinlaitteiden tulee toimia johtavana kappaleena, jonka avulla kuormitusvirrat siirtyvät ilman liiallista lämpenemistä tai suuria häviöitä. (Elovaara & Haarla 2011.) Toimintatila puolestaan jakautuu kahteen eri toiminnallisuuteen: auki- ja kiinniohjaukseen. Aukiohjauksessa sähköverkon kaksi osaa erotetaan toisistaan eli luodaan avoin virtapiiri, jossa virta ei enää kulje. Kiinniohjauksessa puolestaan kaksi verkossa erillään ollutta osaa kytketään yhteen, eli luodaan suljettu virtapiiri, jossa virta pääsee kulkeutumaan. (Elovaara & Haarla 2011.)

### 3.2.1 Katkaisijat

Katkaisija (engl. *circuit breaker*) on voimansiirtoverkon tärkein ja usein myös arvokkain kytkinlaite. Elovaara & Haarlan (2011) mukaan niiden tehtävä on tarpeen vaatiessa avata ja sulkea sähköverkon virtapiiri. Tähän liittyy myös niiden keskeinen ominaisuus kestää suuria virtoja, sillä ne pystyvät vaurioitumatta avaamaan ja sulkemaan moninkertaisia virtoja katkaisijan omaan mitoitusvirtaan nähden. Dou et al. (2018) määrittävät yleisemmällä tasolla, että katkaisijat suojelevat ja ohjaavat sähköverkkoja. Tyypillinen katkaisijassa tapahtuva automaattitoiminto on virtapiirin avaaminen ylivirran, eli esimerkiksi maasulku- tai oikosulkuvirran vaikutuksesta. Tällöin avaamiskäsky syntyy mittamuuntajien avulla kytketystä releestä. Virtapiiri voidaan myös sulkea automatisoidusti esimerkiksi jälleenkytkentäreleistyksen aktivoituessa. (Elovaara & Haarla 2011.) Kaikki katkaisijat eivät kuitenkaan ole automaattiohjattuja, vaan ne voivat toimia myös käsiohjattuina. Elovaara & Haarlan (2011) mukaan vikatilanteissa laukaisu on automaattista, mutta normaalikäytössä toimintakäsky annetaan käsiohjattuna kauko-ohjauksella tai paikanpäältä. Kuvassa 4 on esitetty ABB:n SF<sub>6</sub> kaasukatkaisijan ulkonäkö ja keskeiset osat.



vät katkaisijoissa valokaaren jäähdytyksen ja osituksen keskeisiksi vaikuttajiksi seinärakenteet ja väliaineet. Valokaari lukitaan kiinteiden seinämien sisälle, jolloin koskettaessaan seinämiä valokaari jäähtyy. Katkaisukammioissa väliaineet puolestaan deionisoivat ja jäähdyttävät valokaarta. Nämä molemmat tukevat valokaaren sammutusta.

Katkaisijat voidaan jakaa väliaineen perusteella seuraaviin ryhmiin yleisimmästä harvinaisimpaan:

- SF<sub>6</sub>-kaasukatkaisija (engl. *sulfur hexafluoride circuit-breaker*)
- Vähäöljykatkaisija (engl. *oil-minimum circuit-breaker*)
- Tyhjiökatkaisija (engl. *vacuum circuit-breaker*)
- Paineilmakatkaisija (engl. *air-blast circuit-breaker*)

Tyhjiökatkaisijoita ei ole käytössä Suomen kantaverkossa, ja viimeiset paineilmakatkaisijat poistettiin kantaverkosta vuonna 2017 (Laitinen & Tammi 2018). Tässä tutkimuksessa käsiteltävät katkaisijat ovat SF<sub>6</sub>-kaasukatkaisijoita, joka on ainoa Kymin sähköasemalla oleva katkaisijatyyppe.

### 3.2.2 Katkaisijoiden vikatilat

Kytkeinlaitteiden vikatilat jaetaan yleisesti kirjallisuudessa, mm. Mazza & Michara (1981), Janssen et al. (1994) sekä Lindquist et al. (2008), kahteen vikatyyppeihin: Merkittävät viat, jotka aiheuttavat kytkinlaitteen jonkin keskeisen toiminnon toimimattomuuden. Pienet viat, jotka kattavat kaikki vikatilanteet, joita ei voida laskea merkittäviksi vioiksi. (Mazza & Michara 1981.) Merkittäviksi vikatiloiksi voidaan Janssenin et al. (2014) mukaan lukea seuraavat tilanteet, joissa katkaisija:

- avautuu / sulkeutuu ilman komentoa.
- ei avaudu / sulkeudu komennosta tai jumittuu kiinni- / aukiasentoon.
- ei kuljeta virtaa kiinniasennossa.
- ei avaa / sulje virtapiiriä toimintatilassa.
- tapahtuu läpilyönti maahan tai avoimesta navasta.

Pienemmiksi vioiksi voidaan Janssenin et al. (2014) mukaan lukea esimerkiksi muutos toiminnallisuudessa, kuten aukaisuajan muutos, tai SF<sub>6</sub>-kaasukatkaisijan kohdalla pienimuotoinen kaasuvuoto.

IEEE-SA Standards Boardin (1996) mukaan katkaisijoihin liittyvät ongelmat voidaan jakaa neljään luokkaan: toimintamekanismin vikoihin, sähköisen ohjauksen sekä apupiirin vikoihin, suurjännitekomponenttien vikoihin ja muihin vikoihin. Ongelmatyypit ovat edellä järjestettynä kyseisen tutkimuksen kirjoitushetkellä yleisimmistä harvinaisimpaan, mutta yksityiskohtaisempia numeroita ei ole syytä tarkastella, sillä ohjeessa tarjotut pro-

senttiosuudet koskevat vain tiettyntyyppisiä vuosien 1978 ja 1992 välillä asennettuja katkaisijoita (IEEE-SA Standards Board 1996). Vikatilojen jaottelu on kuitenkin edelleen pätevä, sillä katkaisijoissa ei ole tapahtunut merkittäviä rakenteellisia tai toiminnallisia muutoksia.

Ensimmäisen maailmanlaajuisen tutkimuksen katkaisijoiden vikatilanteista koostivat Mazza & Michara (1981). Selvityksessä (Mazza & Michara 1981) tutkittiin yli 63 kV suurjännitekatkaisijoita 22 eri maasta. Yhteensä katkaisijoilla oli käyttövuosia 77 892. Jopa 70 % merkittävistä ja 86 % pienemmistä vioista johtui mekaanisista häiriöistä. Noin 19 prosenttia merkittävistä ja 12 % pienemmistä vioista johtui apupiiristä ja sähköisestä ohjauksesta. Loput vikatilanteet johtuivat pääpiirin vioista eli itse suurjännitekomponenteista. (Mazza & Michara 1981.) 13 vuotta myöhemmin Janssen et al. (1994) koostivat vastaavan tutkimuksen liittyen myös suurjännitekatkaisijoihin. Tällä kertaa tutkimuksen kohteena olivat yli 72,5 kV SF<sub>6</sub>-kaasukatkaisijat 22 eri maasta, joilla käyttövuosia oli yhteensä 70 708 vuotta. Noin 61 prosenttia merkittävistä ja jopa 89 % pienemmistä vioista liittyi mekaanisiin häiriöihin. Pienempien vikojen kohonnutta lukua selittää kaasukatkaisijan kaasuvuodot, sillä vastaavaa ongelmaa ei ole samalla tavalla muissa katkaisijalaitetyypeissä, joita oli aiemman tutkimuksen aikana runsaammin käytössä. Apupiiristä ja sähköisestä ohjauksesta johtuneita vikoja oli 25 % merkittävistä ja 11 % pienemmistä vioista. (Janssen et al. 1994.) Kokonaisuudessaan laskettaessa vuosittaisia vikoja yksittäiselle katkaisijalle vikojen määrä oli vähentynyt 13 vuoden aikana merkittävässä vioissa arvosta 0,024 arvoon 0,0067 sekä pienemmissä vioissa arvosta 0,063 arvoon 0,0475 (Mazza & Michara 1981; Janssen et al. 1994).

2000-luvun puolella asiaa on tutkinut Runde et al. (2013), jotka koostivat SF<sub>6</sub>-kaasukatkaisijoihin liittyen tutkimuksen vikatilastoista. Mekaaniset ongelmat olivat edelleen suurin aiheuttaja sekä merkittävässä että pienemmissä vioissa. Vikojen määrä oli selkeästi vähentynyt aiempiin tutkimuksiin nähden. (Runde et al. 2013.) Qiu et al. (2016) nostavat esille, että suurin osa vikatilanteista auki- ja kiinniohjauksissa liittyy mekaanisiin vikoihin. Razi-Kazemi et al. (2014) puolestaan käyttivät hieman erilaista jaottelua ja esittävät kirjallisuusselvityksen perusteella, että noin 45 % merkittävistä vioista liittyy mekaanisiin komponentteihin, 29 % virrankatkojiin (engl. *current path interrupters*) ja 26 % apu- ja kontrollipiiriin (engl. *auxiliary and control circuits*). Selvitystyössä huomattiin, että 2000-luvulla tehdyt aihepiirin tutkimukset olivat pääsääntöisesti keskittyneet huomattavasti spesifimpiin tutkimusongelmiin, esimerkiksi tietyn tyyppisiin vikoihin tai tietyn komponentin häiriöihin.

Selkeästi suurimpana merkittävien ja pienten vikatilanteiden aiheuttajana voidaan tunnistaa Mazza & Micharan (1981), Janssen et al. (1994) ja Runde et al. (2013) tutkimuksista katkaisijoiden toimintamekanismin viat. Tämä tukee ajatusta, että laitteiden kuntoa voidaan arvioida äänisignaalin perusteella, sillä toimintamekanismin viat aiheuttavat usein systeemille poikkeuksellista toimintaääntä. Tämä voi ilmetä esimerkiksi kohonneena yleisenä äänitasona tai systeemistä kuuluvina poikkeuksellisina ääninä.


### 3.2.3 Erottimet ja maadoituskytkimet

Kytkeinlaitosten erottimet (engl. *disconnector*) erottavat tai yhdistävät verkon jännitteiset osat jännitteettömistä verkon osista huoltotöiden mahdollistamiseksi. Elovaara & Haarla (2011) tarkentavat, että erottimien avulla voidaan eristää yksittäisiä verkon osia, jotta tarkistuksia ja korjaustöitä voidaan tehdä turvallisesti avausvälillä erotettuna. Erottimet mahdollistavat myös ohituskytkentöjen tekemisen, jolloin yksittäisen laitteen huoltotyöt eivät häiritse koko kytkinaseman sähkönsiirtoa. Elovaara & Haarla (2011) mainitsevat erottimelle kaksi keskeistä turvallisuuteen liittyvää tehtävää: Erottimen täytyy pystyä omaamaan suurempi avausvälin jännitelujuus kuin ympäröivässä eristyksessä on. Toiseksi avausvälin tulee olla näkyvä tai muutoin havaittavissa, jolloin erottimen hetkellinen tilanne pystytään selkeästi tunnistamaan. Kylmissä olosuhteissa, kuten Suomessa, erottimilta edellytetään lisäksi hyvää pakkasenkestävyyttä ja niiden tulee pystyä käyttötilanteessa murtamaan jopa 2 cm jääkerros. (Elovaara & Haarla 2011.)

Erottimet voidaan jakaa kolmeen laiteryhmään:

- Tartuntaerottimet (engl. *pantograph disconnector*)
- Kiertoerottimet (engl. *break disconnector*)
- Veitsierottimet (engl. *knife switch disconnector*)

Veitsierottimia, joiden toiminta perustuu yhden tukipisteen varassa olevan kosketinvarren liikkumiseen pystysuunnassa, ei juurikaan käytetä kantaverkossa (Elovaara & Haarla 2011), eikä niitä tästä syystä käsitellä tässä tutkimuksessa tarkemmin. Erottimia voidaan jaotella laiteryhmiin lisäksi tarvittavien tukieristimien lukumäärän sekä koskettimien liikkumissuunnan perusteella. Elovaara & Haarla (2011) korostavat, että nimityksistä uupuu standardointia ja valmistajat saattavat käyttää vastaavista laitteista eriäviä nimityksiä.



**Kuva 5.** Siemensin 3DN3 saksityyppisen tartuntaerotin keskeiset komponentit (mukaillen lähdettä Siemens 2018)

Kuvassa 5 on esitetty Siemensin 3DN3 saksityyppisen tartuntaerotin keskeiset komponentit. Kuvassa näkyvä tartuntaerotin on auki-tilassa, sillä sen kosketinvarret ovat asetettu alas, eivätkä tartuntapihdit koske mihinkään. Kiinniohjauksessa eli yhdistettäessä kyseinen verkon osa takaisin muuhun verkkoon nousevat kosketinvarret pystysuoriksi ylöspäin, jolloin tartuntapihdit ovat fyysisessä kontaktissa verkon toiseen osaan. Elovaara & Haarlan (2011) mukaan tartuntaerotimia voi esitellyn saksierotimen lisäksi olla rakenteeltaan vertikaalisia ja horisontaalisia tartuntaerotimia, jolloin varret ovat suoravaraisia, mutta liike tapahtuu eri suunnissa. Erilaisten tartuntaerotimien rakenteet vaativat eriäviä määriä asennuspinta-alaa, sopivat tietyn tyyppisiin sähkölaitoksiin ja ovat kustannuksiltaan poikkeavia (Elovaara & Haarla 2011).

Yleisin erotinmalli on kiertoerotin, jossa kosketinvarret avautuvat kiertoliikkeellä. Elovaara & Haarlan (2011) mukaan tavallisin kiertoerotinmalli on vaakatasossa liikkuva kaksipilarinen erotin. Tämän lisäksi kiertoerotimia on olemassa kolmipilarisia, joissa kiertoliike tapahtuu kosketinvarsilla vastakkaisiin kiertosuuntiin, sekä pystysuuntaisia kiertoerotimia, jotka on mahdollista asentaa ahtaaseenkin sijaintiin (Elovaara & Haarla 2011).

Erottimet voidaan laiteryhmiä lisäksi jakaa myös ohjaustavan perusteella. Tyypillisesti erotinlaitteet ovat moottori- tai käsiohjattuja. Elovaara & Haarlan (2011) mukaan käsiohjauksia suoritetaan yleensä eristävällä tangolla. Moottoriohjauksia voidaan suorittaa joko paikan päältä tai kaukokäyttöisesti. Lakervi & Partanen (2008) korostavat, että kaukokäyt-



töiset moottoriohjaukset voivat luoda merkittäviä taloudellisia säästöjä ja toimintavarmuuden parantamista erityisesti syrjäisemmällä seudulla ja keski- tai pienjänniteverkossa. Keskeytyksen korjaaminen ilman kauko-ohjattavuutta voi kestää pitkäänkin, mikäli lähistöllä ei ole vikatilanteessa korjausmiehistöä. Kauko-ohjattavuuden avulla vialliset verkon osat voidaan eristää muusta verkosta nopeasti. (Lakervi & Partanen 2008.)

Elovaara & Haarlan (2011) mukaan maadoituskytkin (engl. *earthing disconnecter*) on tietyn tyyppinen erottimen käyttötapa. Tämän takia maadoituskytkimiä kutsutaankin useissa yhteyksissä maadoituserottimiksi. Niitä käytetään estämään indusoituneen jännitteen ja vikavirran aiheuttamat vaaratilanteet. Tämä mahdollistaa verkossa työskentelyn, mutta ei yksinään riitä, vaan toimii ennemminkin työmaadoitusten ohessa. Turvallisuus- ja kemikaaliviraston tekemässä onnettomuustutkintaraportissa (Hatakka et al. 2013) esitetään maadoituskytkimien roolin olevan estää työstettävän kohteen muuttuminen jännitteiseksi. Tällainen tilanne saattaa syntyä esimerkiksi kytkinlaitteen virheikäytön tai odottamatta laitteistoon tulleen jännitteen vuoksi, esimerkiksi risteävät tai rinnakkaiset johdot voivat aiheuttaa tällaisen tilanteen (Hatakka et al. 2013). Toiminnaltaan ja komponenteiltaan maadoituskytkin on niin lähellä erotinta, ettei sen yksityiskohtaisempi tarkastelu ole tämän tutkimuksen kannalta tarpeellista. Tässä luvussa puhuttaessa erottimista tarkoitetaan tällä myös maadoituskytkimiä.

### 3.2.4 Erottimien ja maadoituskytkimien vikatilat

Tunnuslukujen osalta kirjallisuudesta on huomattavissa, että erottimia ja maadoituskytkimiä käsitellään usein yhdessä (mm. Runde et al. (2012), Runde (2013)) Tämän lisäksi selvitystyön pohjalta nousi huomio, että puhtaasti maadoituskytkimiä käsittelevää tutkimusta on saatavilla hyvin vähän ja tästä syystä myös tässä tutkimuksessa erottimien ja maadoituskytkimien tunnuslukuja käsitellään yhtenä kokonaisuutena.

Runde et al. (2012) määrittelevät kansainvälisessä erottimien ja maadoituskytkimien luotettavuutta käsitelleessä tutkimuksessa laitteiden merkittäviksi vikatiloiksi seuraavat:

- ei avaudu / sulkeudu komennosta
- avautuu / sulkeutuu ilman komentoa
- ei kuljeta virtaa
- virran kanssa tapahtuu läpilyönti
- laitteisto jumittuu auki- tai kiinniasentoon
- mekaaninen vioittuminen.

Vastaavalla tavalla kuin katkaisijoissa myös erottimissa ja maadoituskytkimissä pienemmiksi vikatiloiksi lasketaan kaikki vikatilat, jotka eivät ole merkittäviä vikoja, eli esimerkiksi mekaanisten tai sähköisten ominaisuuksien muuttuminen (Runde et al. 2012). Selkeästi yleisimpänä merkittävänä vikatilanteena sekä erottimilla (70 % vioista) että maa-

doituskytkimillä (79 % vioista) on komentoon vastaamattomuus eli tilanne, jossa annetusta komennosta huolimatta mitään ei tapahdu. Erottimien (14 % vioista) ja maadoituskytkimien (7,4 % vioista) toiseksi yleisin merkittävä vikatila on mekaaninen vioittuminen. Kolmanneksi yleisin molemmilla laitetyypeillä on jumittuminen auki- tai kiinniasentoon, joka kattaa erottimilla 6,7 % vioista ja maadoituskytkimillä 7,0 % vioista. (Runde et al. 2012.)

Runde et al. (2012) käsittelevät tutkimuksessaan 504366 käyttövuotta omaavaa erotin ja 127243 käyttövuotta omaavaa maadoituskytkinpopulaatioita, joissa ilmeni tarkasteluvuosien 2004 ja 2007 välillä 1493 erottimen ja 298 maadoituskytkimen merkittävää vikatilaa. Erottimilla 19 % vioista liittyi maadoitettuun toimintamekanismiin ja 25 % muuhun toimintamekanismiin. 22 % vioista liittyi pääpiiriin sekä 25 % apu- ja kontrollipiiriin sähköisiin vikoihin. Loput viat eivät olleet lähtöisin mainituista pääkategorioista. Maadoituskytkimien osalta 19 % vioista liittyi maadoitettuun toimintamekanismiin ja 22 % muuhun toimintamekanismiin. 9 % ongelmista oli pääpiiriin liittyviä sähkövikoja ja selkeästi suurin osuus, jopa 42 %, liittyi apu- ja kontrollipiiriin sähköisiin vikoihin. (Runde et al. 2012.) Tutkimuksen (Runde et al. 2012) perustella pystytään tunnistamaan kahtena selkeästi suurimpana vianlähteenä sähkö- ja toimintamekanismiin liittyvät viat, jotka yhdessä kattavat sekä erottimilla että maadoituskytkimillä vähintään 90 % kaikista merkittävistä vikatilanteista.

Brodersson et al. (2016) tutkivat Ruotsin erotinpopulaatiosta vuosien 2008 ja 2015 väliltä kerättyä aineistoa. Merkittävistä vikatilanteista 36 % liittyi erottimien toimintamekanismiin ja 31 % apu- ja kontrollipiiriin. Loput vikatilanteista olivat kohdistettu määrittämättömille syyille. Brodersson et al. (2016.) huomauttavat, että merkittäviä vikatilanteita oli jopa kaksinkertainen määrä etäohjatuissa erottimissa verrattuna käsiohjattuihin. Tämän syyksi he nostavat kontrollipiiriin liittyvät vikatilat. Qiu et al. (2014) nostavat esille, että jopa 70 % erottimien vikatilanteista liittyi mekaanisiin tekijöihin. Tämän yleisimmäksi syyksi he esittävät virheellistä asennusta ja metallikomponenttien ruostumista (Qiu et al. 2014).

Vastaavalla tavalla kuin katkaisijoissa myös erottimilla ja maadoituskytkimillä merkittävä osa vioista liittyy toimintamekanismiin. Kuten katkaisijoiden kohdalla todettiin, mahdollistaa tämä vikatilann tunnistamisen nauhoitetun äänen perusteella. Osa sähköpiireihin liittyvistä vioista on puolestaan mahdollista tunnistaa moottorin virran käyttöä tarkkailemalla. Moottorivirran tarkastelulla voidaan havainnoida myös osissa tapahtuvaa muuntautumista, sillä esimerkiksi jumiutumisesta voivat kasvattaa virrankäyttöä (Laitinen & Tammi 2018).

## 4. DATAOHJATTU PÄÄTÖKSENTEKO

Tässä luvussa käsitellään dataohjattuun päätöksentekoon ja analytiikkaan liittyviä erityispiirteitä. Ensimmäinen alaluku keskittyy esittelemään yleisesti dataohjattuun päätöksentekoon ja siihen siirtymiseen vaikuttavia tekijöitä, nostaen esille myös ennustavan kunnossapidon kontekstia. Dataohjatun päätöksenteon lähtökohtien jälkeen tarjotaan käsitys analytiikkakehityksen ja -projektien luonteesta analytiikan prosessimallien avulla. Näistä esitellään CRISP-DM ja visuaalinen analytiikka. Viimeisessä alaluvussa prosessimallien rinnalle tuodaan korkeamman tason organisatorinen näkökulma analytiikan sekä IoT-analytiikan tasojen avulla.

### 4.1 Dataohjatun päätöksenteon lähtökohdat

Datan kerääminen ja hyödyntäminen ovat tulossa jo toimialasta riippumatta keskeiseksi menestystekijäksi. Organisaatiot, jotka eivät hyödynnä dataa toiminnassaan, ovat vaarassa jäädä alati kovenevassa kilpailussa altavastajiksi. Dataan pohjautuva päätöksenteko ja analyysi mahdollistavat parhaimmillaan uusia liiketoimintamalleja, mutta vähimmilläänkin muokkaavat nykyisiä toimintatapoja ja prosesseja. Merkittävä osuus dataohjattuun päätöksentekoon liittyvästä tutkimuksesta ennustavan kunnossapidon alueella on keskittynyt tekniseen puoleen, kuten datan keräämiseen ja analyysimenetelmiin (Koochaki & Bouwhuis 2008; Dadashi et al. 2014; Golightly et al. 2017). Vähemmälle huomiolle on jäänyt asiaan liittyvät pehmeät tekijät kuten vaikutukset yksilöihin, organisaation johtamiseen ja toimintatapoihin. Muun muassa Dadashi et al. (2014), Kefalidou et al. (2015) sekä Golightly et al. (2017) nostavat esille, että käytännössä huomattavasti teknisiä tekijöitä haastavammaksi voivat muodostua ihmisten tottumattomuus datan käsittelyyn, siihen luottamiseen ja organisatoriset hidasteet kuten strategia tai johtamistapa. Golightly et al. (2017) huomauttavat tämän korostuvan entisestään toimialoilla, joissa infrastruktuurin elinkaari on pitkä, jolloin datapohjaista ohjaamista lähestytään implementoimalla antureita osaksi jo olemassa olevaa tarkastelukohdetta. Tällaisina toimialoina voidaan pitää esimerkiksi valmistavaa teollisuutta, rautatietojärjestelmien tai energia-alaa.

Yleisemmällä tasolla dataohjattu päätöksenteko voidaan nähdä toimintatapana, jossa päätöksiä tehdään pohjautuen kerättyyn dataan ennemmin kuin ihmisten empiirisiin havaintoihin tai intuitioon. McAfee & Brynjolfssonin (2012) tutkimuksen mukaan, mitä enemmän organisaatiot luokittelevat toimintaansa dataohjatuksi, sitä paremmin ne suoriutuivat selkeästi mitattavilla mittareilla kuten talouslukujen tai operatiivisen toiminnan valossa. Vaikka poikkeuksiakin löytyi, olivat kyseisen selvityksen tulokset tilastollisesti merkitseviä ja keskimäärin dataohjatut yritykset olivat 5 % tuottavampia ja 6 % kannattavampia

kuin vastaavat organisaatiot, joita ei kategorisoitu dataohjautuviksi (McAfee & Brynjolfsson 2012). Schrage (2016) puolestaan nostaa esille, että dataohjattu päätöksenteko ei vaikuta ainoastaan lopputuloksena syntyviin valintoihin, vaan merkittävästi myös päätöksentekoprosessiin ja siihen osallistuviin henkilöihin. Valintojen lisäksi myös päätöksentekijöiden valinnan tulee tapahtua dataohjautuvasti ja datalla on oltava selkeä omistaja, jotta sen luotettavuudesta sekä hyödynnettävyydestä voidaan olla varmoja (Schrage 2016). Päätöksentekijällä on dataohjautuvuudesta huolimatta merkitystä, sillä suurimassa osassa päätöksentekotilanteita ihmisellä on edelleen merkittävä osuus ja tilanteen ymmärtäminen edellyttää substanssiymmärrystä käsiteltävästä aihepiiristä pelkän datan tulkinnan lisäksi (McAfee & Brynjolfsson 2012).

McAfee & Brynjolfsson (2012) sekä Marr (2017) korostavat dataohjatun päätöksenteon yhtenä keskeisenä ongelmakohteena olevan luottaminen päätöksenteossa korkeimmin palkattuun päättäjään. Tällä kirjoittajat tarkoittavat, että mikäli käytössä oleva datan pohjalta kootut analyysit eivät kykene päätöksentekohetkellä vastaamaan esitettyyn kysymykseen, siirtyy vastuu ja ratkaisu usein korkeimmalle auktoriteetille. Ratkaisuksi kirjoittajat ehdottavatkin, että tämän päättäjän roolin pitäisi muuttua vastausten antajasta oikeiden kysymysten ja ongelmien määrittäjäksi, jolloin mahdollistetaan datapohjainen ratkaisu käsiteltävään ongelmaan. (McAfee & Brynjolfsson 2012; Marr 2017.)

McAfee & Brynjolfsson (2012) tunnistavat viisi tekijää, jotka organisaatioiden tulee huomioida onnistuakseen dataohjatussa päätöksenteossa: Johtamisen tulee mahdollistaa ja kannustaa oikeaoppiseen päätöksentekotoimintaan unohtamatta inhimillistä puolta. Teknologian tulee olla modernia ja pystyä käsittelemään suuria datamääriä tehokkaasti. Päätöksentekoprosessien tulee mahdollistaa oikeiden henkilöiden pääsy dataan ja sen hyödyntämiseen. Henkilöstön osaaminen saattaa vaatia muutoksia, sillä analyysien tuottaminen vaatii monessa tilanteessa analyytikoita ja datatieteilijöitä, jotka osaavat datan käsittelyn lisäksi ymmärtää liiketoimintaongelmien mallintamista matemaattiseen muotoon. Viimeisenä tekijänä kirjoittajat nostavat esille organisaatiokulttuurin, jonka pitää tukea avointa datapohjaista päätöksentekoa. Kulttuurin ei pidä kannustaa omien intuitiolla tehtyjen päätösten perusteluun datan avulla, vaan avoimeen ratkaisun etsimiseen datalähtöisesti, jonka hyvyttä lopuksi arvioidaan inhimillisemmästä näkökulmasta. (McAfee & Brynjolfsson 2012.)


Dataohjatun ennustavan kunnossapidon osalta suurin osa tutkimuksesta on keskittynyt tarvittavaan teknologiaan ja analyysimenetelmien käsittelyyn (Golightly et al. 2017). Todellisuudessa ongelmia aiheutuu merkittävässä määrin yksilöiden ja organisaatioiden tasoilla. Golightly et al. (2017) esittävät dataohjattuun ennustavaan kunnossapitoon liittyen viisi tekijää, jotka implementoinnissa on huomioitava: Muutoksen toimitus on oltava tehokas ja siinä tulee huomioida henkilöstön osaaminen, prosessin iteratiivisuus ja sen on tapahduttava päätöksenteko edellä. Organisaatiokulttuurin on oltava vastaanottava muutokselle. Tähän vaikuttavat niin riskinotto-kyky, strategia, ratkaisun arvon osoittaminen ja yleinen johtaminen. Kolmanneksi, toimitusketjun toimijat on pidettävä tiukasti mukana

muutoksessa, tarkoittaen niin tiedon jakamista oman organisaation ulkopuolelle kuin myös tehtävän yhteistyön määrää. Yhteistyötä suositellaan myös muiden alan toimijoiden kanssa esimerkiksi toimialarahoituksen tai osaamiskeskusten muodossa. Viidentenä asiana korostetaan muutoksen resursointia eli sille varattavaa aikaa, henkilöstön kouluttamista ja tarvittavaa rahoitusta. (Golightly et al. 2017.) Edellä esitellyistä muutoksessa huomioitavista seikoista voidaan huomata, kuinka pienessä roolissa teknologia ja analyysi enää ratkaisun implementoinnin vaiheessa ovat. Riippumatta siitä kuinka tarkkaa ja luotettavaa informaatiota tarjoava ennustavan kunnossapidon analytiikkaratkaisu on, ei se luo organisaatiolle arvoa, mikäli käyttäjät eivät halua ja suostu käyttämään sitä.

Edellä esitellyistä dataohjatun päätöksen mahdollistajista huomataan nopeasti, kuinka pienessä roolissa teknologinen puoli kokonaisuudessaan on, ja miten senkin suurimmat haasteet liittyvät oikeanlaisen osaamisen hankintaan. Samaa oikeaoppiseen osaamiseen liittyvää haastetta korostavat myös Davenport & Patil (2012), jotka huomauttavat omien datatieteilijöiden puutteen riskeeraavan pitkässä juoksussa organisaatioiden kilpailukykyä. Dataohjattuun päätöksentekoon liittyviä ominaispiirteitä on helpompi ymmärtää analytiikan prosessimallien kautta, joista tässä luvussa esitellään seuraavaksi CRISP-DM sekä visuaalinen analytiikka.

## 4.2 Analytiikan prosessimalli: CRISP-DM

CRISP-DM (*Cross-industry standard process for data mining*) on toimialariippumaton tiedonlouhintamenetelmä, joka mahdollistaa analyysien tekemisen olemassa olevasta tietaineistosta. Prosessimallia ei ole tarkoitettu yksityiskohtaiseksi säännöstöksi tiedonlouhinnassa onnistumiseen, vaan ennemminkin korkean tason ohjeeksi siitä, mitkä ovat keskeisimpiä vaiheita, joita tiedonlouhinnassa on otettava huomioon. (Chapman et al. 2000; Shearer 2000.) Bosnjak et al. (2009) nostavat esille, että vaikka kyseessä on prosessimalli, jota voi edetä askel kerrallaan eteenpäin, on tyypillisempää, että vaiheiden välillä siirrytään toisinaan myös takaisin edeltävään vaiheeseen ymmärryksen kehittyessä. Tämä on hyvin yleistä, sillä eri vaiheissa tehtävät havainnot selittävät myös muita vaiheita, jolloin voidaan joutua arvioimaan uudestaan aiemmissa vaiheissa tehtyjä päätelmiä (Bosnjak et al. 2009).



**Kuva 6.** CRISP-DM prosessimalli (suomennettu lähteestä Bosnjak et al. 2009)

Kuvassa 6 nähtävän CRISP-DM:n prosessimallin mukaan tiedonlouhinta voidaan jakaa kuuteen eri vaiheeseen: liiketoimintaymmärrys, datan ymmärrys, datan valmistelu, mallinnus, arviointi ja käyttöönotto (Shearer 2000). Liiketoiminnan ymmärrys on olennainen lähtökohta jokaisella tiedonlouhintaprojektilla. Siinä ymmärretään käsiteltävä konteksti ja muotoillaan liiketoimintaongelma datalla vastattavaan muotoon. Liiketoimintaymmärrys itsessään koostuu useasta vaiheesta, mm. tilanteen määrittelystä, projektisuunnittelusta ja liiketoimintatavoitteiden päättämisestä. Datan ymmärrys –vaihe puolestaan voidaan jakaa neljään tehtävään: lähtödatan keräämiseen, datan kuvailuun, datan tutkimiseen ja datan laadun varmistamiseen. Datan ymmärryksessä tuotetaan usein visualisointeja tai kokonaisraportteja, jolla datan muotoa voidaan selventää myös muille. (Chapman et al. 2000; Shearer 2000)

Shearerin (2000) mukaan datan valmistelu –vaiheessa suoritetaan kaikki toimenpiteet, joiden avulla aineisto saadaan mallinnettavaan muotoon. Nämä toimet voidaan jakaa viiteen vaiheeseen: datan valikointi, datan siivoaminen, datan kokoaminen, datan integrointi ja datan formatointi. Neljännessä vaiheessa eli mallinnuksessa iteroidaan erilaisia menetelmiä ja parametreja mahdollisimman hyvin dataa selittävän mallin löytämiseksi. Eri mallit vaativat usein erimuotoista dataa syötteenä, joten mallinnuksesta joudutaan usein palaamaan takaisin datan valmisteluun. Mallinnusvaihe voidaan jakaa seuraaviin

osiin: mallinnustekniikan valinta, testiasettelun luominen, mallin luonti ja mallin arviointi. Viides vaihe sisältää arvioinnin. Arvioinnin tehtävänä on tarkastella kehitetyn mallin suoriutumista suhteessa asetettuihin liiketoiminnallisiin tarpeisiin. Tämä on usein projektipäällikön tai muun ohjaavan tahon tehtävä. Arviointi voidaan jakaa kolmeen tehtävään: tulosten arviointiin, prosessin tarkasteluun ja seuraavien tehtävien määrittämiseen. (Shearer 2000.) Arvioinnista on mahdollista palata aiemmin saavutettujen tuloksien kanssa takaisin liiketoiminnan ymmärrykseen, mikäli nähdään ettei saavutetuilla tuloksilla ole tarpeellista hyötyä käyttöönotossa, vaan ne ennemminkin antavat pohjaa uudelle lähestymistavalle.

CRISP-DM prosessimallin viimeinen vaihe eli käyttöönotto pitää sisällään kehitetyn artefaktin viemisen organisaation käyttöön (Shearer 2000). Käytännössä tämä voi tarkoittaa esimerkiksi loppuraportin tuottamista tai visualisointikojelaudan julkaisemista. Shearer (2000) nostaa esiin käyttöönoton keskeiset vaiheet: käyttöönoton suunnittelu, valvonnan ja ylläpidon suunnittelu, loppuraportin tuottaminen ja projektin arviointi. Käyttöönotosta vastaa usein eri henkilö kuin analyysin tuottanut tekijä. (Chapman et al. 2000.) CRISP-DM prosessimallista on keskeistä ymmärtää, ettei kyseessä ole kertaalleen läpikäytävä prosessi, vaan ennemminkin jatkuva projekti, jonka edeltävät löydökset kehittävät ja luovat pohjaa tuleville iteraatioille.

CRISP-DM prosessimalli on iältään nopeasti kehittyvässä toimialakentässä melko vanha, sillä se kehitettiin vuonna 1996 ja saavutti suurimman suosionsa 2000-luvun alussa (Bosnjak et al. 2009). Teknologia on kehittynyt merkittävässä määrin 20 vuoden aikana ja nykypäivänä mallille esitetäänkin kritiikkiä sen mukautumisesta suuriin datamassoisiin ja esimerkiksi pilvipalvelujen mahdollistamiin toimintamalleihin (Grady et al. 2017). Tästäkin huolimatta se on perustana useille myöhemmin kehitetyille prosessimalleille (mm. Grady et al. 2017) ja toimialariippumattomuutensa ansiosta erinomainen lähtökohta organisaatioille, jotka ovat analytiikan hyödyntämisen osalta alkutaipaleella.

CRISP-DM:än kuten myös useisiin muihin analytiikan prosessimalleihin liittyvät olennaisena osana ketterät (engl. *agile*) toimintatavat, jotka saivat alkunsa tarpeesta hallita projekteja, joihin liittyy epävarmuutta ja tarvetta mukautua ilmeneviin muutoksiin. Samaan aikaan projektien monimutkaistuesssa odotukset tuloksia ja tuottavuutta kohtaan kasvoivat. (Fernandez & Fernandez 2008.) Tämä edellytti siirtymistä pois perinteisistä toimintatavoista, kuten ohjelmistopuolella vesiputousmallista (Serrador & Pinto 2015). Ketterillä toimintatavoilla projektia ja yksittäisiä prosesseja pystytään tarpeiden mukaan muuntamaan kesken toiminnan, kun oppimista ja ymmärrystä tapahtuu (Fernandez & Fernandez 2008; Serrador & Pinto 2015). Alkuperäisen Agile-manifestin (Beed et al. 2001) mukaan ketterä toiminta perustuu seuraavaan neljään toimintaperiaatteeseen: Yksilöt ja niiden kanssakäyminen korostuvat menetelmien ja työkalujen sijaan. Kattavan dokumentaation sijaan olennaista on toimiva ohjelmisto. Asiakasyhteistyö on tärkeämpää kuin sopimusneuvottelu. Keskeisempää on vastata muutokseen kuin pysyä suunnitel-

massa. (Beck et al. 2001.) Serrador & Pinto (2015) korostavat, että yksityiskohtaisen etukäteisen suunnittelun sijaan, suunnittelua tulee tapahtua koko projektin ajan, jolloin muutoksiin vastaaminen on mahdollista.

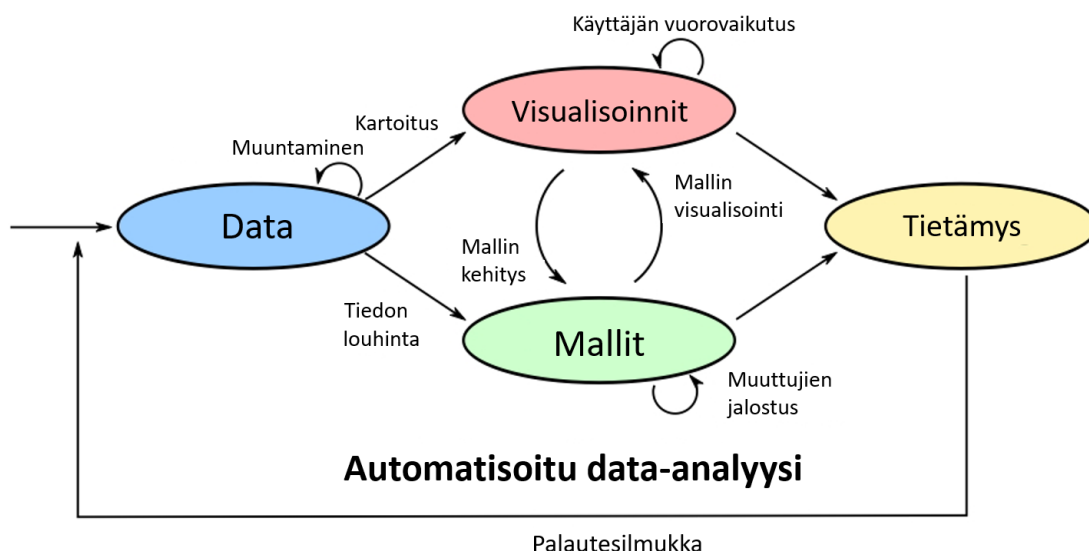
Ketterät toimintamallit ovat peräisin ohjelmistoprojekteista, mutta ovat myöhemmin suosionsa ja toimivuutensa myötä levinneet myös muun tyyppisiin projekteihin (Serrador & Pinto 2015). Alkuperänsä puolesta ketteriä toimintatapoja on sovellettu tiiviisti myös analytiikkaprojekteihin. Larson & Chang (2016) nostavatkin esille, että ketterät menetelmät sopivat erityisen hyvin analytiikkaan, sillä niiden väliltä on löydettävissä useita yhtäläisyyksiä kuten kokeilemiskulttuuri ja pienten tulosten tuottaminen nopealla syklillä. Analytiikan soveltuvuutta ketteriin toimintatapoihin lisää sen iteratiivisuus, jossa tuotettuja visualisointeja iteroidaan ja niistä saatavilla löydöksillä luodaan pohjaa seuraaville toimille (Larson & Chang 2016).

### 4.3 Analytiikan prosessimalli: Visuaalinen analytiikka

Thomas & Cookin (2005) mukaan visuaalinen analytiikka (engl. *visual analytics*) voidaan määrittää prosessiksi, jossa ihminen ja kone vuorovaikutuksessa analyttisesti tulkitsevat suuria määriä kompleksista dataa. Myöhemmin Kohlhammer et al. (2011) tarkensivat määritelmää käsittämään koneen mahdollistamat automaattiset ja laskentaintensiviset analyysitavat yhdistettynä ihmiselle ominaiseen havainnointiin ja johtopäätösten tekemiseen. Visuaaliseen analytiikkaan liittyvät usein interaktiiviset visualisoinnit, jotka mahdollistavat monimutkaisista tietoaaineistoista tehtävän päättelyn, tehokkaan ymmärtämisen ja päätöksenteon (Kohlhammer et al. 2011). Wong & Thomas (2004) korostavat, että visuaalinen analytiikka on saanut alkunsa osana informaation visualisointia ja tieteelistä visualisointia, mutta se on saanut vaikutteita myös tiedonhallinnasta, psykologiasta ja tilastotieteestä. Larson & Chang (2016) nostavat esille, että termistö ei ole järkevästi vakiintunutta, vaan visuaalisesta analytiikasta käytetään paikoitellen myös termiä nopea analytiikka (engl. *fast analytics*). Nopea analytiikka kuitenkin viittaa puhtaammin nopeisiin tapoihin hankkia ja visualisoida dataa.



## Visuaalinen datan eksplorointi



**Kuva 7.** Visuaalisen analytiikan prosessimalli (suomennettu lähteestä Kohlhammer et al. 2011)

Kuvassa 7 esitellyssä visuaalisen analytiikan prosessimallissa on nähtävissä suuntauksen keskeinen ajatus, jossa ihminen ja kone tekevät yhteistyötä optimaalisen lopputuloksen saavuttamiseksi. Prosessimalli lähtee liikkeelle olemassa olevasta data-aineistosta, jota usein joudutaan muuntamaan, jotta sitä voidaan jalostaa eteenpäin. Tällä muuntamisella viitataan esimerkiksi virheellisten arvojen poistamiseen, tietotyyppien käsittelyyn tai arvojen uudelleenskaalaamiseen. Jotta dataa voidaan mallintaa, on sitä ymmärrettävä syvällisemmin. Tämä tarkoittaa datan kartoitusta visualisointien muodossa. Kartoituksessa luodaan usein kuvaajia tai lasketaan tunnuslukuja yksittäisille parametreille, mallinnustyön mahdollistamiseksi. Visualisointien pohjalta tai yksinkertaisissa tilanteissa jopa suoraan datasta voidaan kehittää malleja, joiden avulla voidaan tehdä dataan pohjautuvia suosituksia tai päätöksiä. Andrienko et al. (2018) nostavat esille, että malleilla ei tarkoiteta pelkästään teknisiä malleja, kuten ennustamisessa käytettäviä koneoppimismalleja, vaan ne voivat yhtälailla olla esimerkiksi mentaali- tai käytösmalleja, jotka selittävät reaaliaikailman tapahtumaa.

Mallien tuottaminen on usein iteratiivinen prosessi, jossa pohjaksi haetaan entistä paremmin aineistoa selittäviä muuttujia ja menetelmiä. Mallien laatua on mahdollista arvioida niin tunnuslukujen, kuten keskineliövirheen neliöjuuren, perusteella kuin myös empiirisempien visualisointien avulla. Kohlhammerin et al. (2011) visuaalisen analytiikan prosessikaaviossa tämä näkyy iteroimisena mallien ja visualisointien välillä. Esimerkiksi luokittelutehtävässä malliin perustuvia klustereita voidaan visualisoida pistediagrammilla antamalla ryhmittymille eri värit, jolloin ihminen pystyy havainnoimaan visuaalisesti mallin laatua. Dataa selittävien visualisointien ja mallien perusteella voidaan päätöksentekijälle luoda tietämystä käsiteltävään ongelmaan liittyen. Data auttaa selittämään olemassa olevaa ilmiötä sekä käyttäytymistä, ja mallien avulla voidaan mahdollistaa myös

esimerkiksi luokittelu tai ennustaminen. Olennaisena osana prosessikaaviota tietämyksestä palaa palautesilmukka takaisin lähtöpisteeseen. Tämä tarkoittaa niin datan keräämisen kehittämistä kuin myös datan tarkastelua erilaisesta näkökulmasta saavutetun ymmärryksen avulla.

Visuaaliseen analytiikkaan liittyy myös haasteita (Shneiderman 1996; Keim et al. 2006; Kohlhammer et al. 2011). Shneiderman (1996) esittää informaation visualisoinnin keskeiseksi prosessiksi seuraavat vaiheet: anna yleiskuva datasta, tarkenna sekä suodata ja lopuksi tarjoa yksityiskohtia tarpeen mukaan. Samalla Shneiderman (1996) kuitenkin huomauttaa, että suurien data-aineistojen kohdalla on joskus jopa mahdotonta tarjota todellista yleiskuvaa piilottamatta oleellisia datan ominaisuuksia. Tämä puolestaan hankaloittaa datan ymmärtämistä, koska käyttäjälle ei anneta viitteitä asioista, joita kannattaa datasta etsiä (Shneiderman 1996; Kohlhammer et al. 2011). Keim et al. (2006) ehdottavatkin, ettei yleinen datan visualisointi ole mielekäästä, vaan visualisointia pitäisi aina lähestyä arvonluonnin näkökulmasta. Tätä perustellaan mm. suuriin datamassoihin, ihmisten tekemiin tulkintoihin ja organisaatioissa olemassa oleviin prosesseihin liittyvillä tekijöillä (Keim et al. 2006).

Visuaalisessa analytiikassa on keskiössä iteratiivisuus ja jatkuva ihmisen ja koneen yhteistyö. Visuaalinen analytiikka ei siis ole oikea lähestymistapa jatkuvaan ylläpitoratkaisuun, jossa halutaan koneellisesti tunnistaa tietyn tyyppisiä tilanteita, esimerkiksi ennustavan kunnossapidon lopputuote ei ole visuaalista analytiikkaa. Lähestymistavalla on kuitenkin paikkansa prosessissa, jossa mahdollistetaan jatkuvassa käytössä olevan järjestelmän toiminta. Visuaalisella analytiikalla ymmärretään dataa, luodaan mahdollisuudet datan hyödyntämiselle, kehitetään hyödynnettävää mallia ja tarjotaan ymmärrystä käsiteltävästä ongelmasta. Tämän takia visuaalinen analytiikka on usein keskeisessä roolissa tuotaessa dataohjattua päätöksentekoa osaksi organisaatiokulttuuria.

## 4.4 Analytiikan tasot

Davenport (2014) jakaa analytiikan kolmeen eri tasoon tuotettavan analyysin käyttötarkoituksen perusteella: kuvailevaan (engl. *descriptive*), ennustavaan (engl. *predictive*) ja ohjaavaan (engl. *prescriptive*) analytiikkaan. Kuvaileva analytiikka keskittyy jo tapahtuneiden asioiden tulkitsemiseen ja ymmärtämiseen eli siihen liittyy olennaisena osana datan keruu ja sen kuvailu. Kuvaileva analytiikka ymmärretään usein perinteisenä raportointina, joilla selitetään aiemmin olleita tapahtumia. (Davenport 2014.) Delen & Demirkan (2013) tarkentavat kuvailevan analytiikan pitävän sisällään niin tietovarastointia, lakisääteistä sekä ad-hoc raportointia kuin myös dynaamisempaa olemassa olevan datan tutkimista ja visualisointinäkökymien luomista. Kuvailevan analytiikan keskeisenä tarkoituksena on tunnistaa liiketoiminnan haasteita ja mahdollisuuksia (Delen & Demirkan 2013).

Ennustavan analytiikan tarkoituksena on Davenportin (2014) mukaan hyödyntää olemassa olevasta datasta luotuja tilastollisia malleja tulevaisuuden ennustamiseen. Delen & Demirkan (2013) nostavat esille ennustavan analytiikan vastaavan kysymyksiin: mitä ja miksi tulee tapahtumaan? Ennustavaan analytiikkaan liittyviin menetelmiin ovat perinteisesti kuuluneet mm. tiedonlouhinta, yksinkertainen koneoppiminen ja tekstilouhinta. Ennustavan analytiikan tarkoituksena on antaa jo tapahtuneiden tilanteiden perusteella ennustuksia mitä todennäköisemmin tulee tapahtumaan. (Delen & Demirkan 2013.)

Ohjaava analytiikka puolestaan on tarkoitettu antamaan suosituksia siihen, miten tulisi toimia. Keskeinen osa ohjaavaa analytiikkaa on tulkittavien asioiden syy-seuraus -suhteiden ymmärtäminen. (Davenport 2014.) Delenin & Demirkan (2013) mukaan ohjaava analytiikka voi pohjautua pelkkään dataan, asiantuntijoiden ammattitaitoon tai useimmiten näihin molempiin. Tähän tasoon liittyvät useimmiten esimerkiksi simulointi, optimointi, asiantuntijajärjestelmät ja päätöksentekoa tukevat järjestelmät. Ohjaavan analytiikan tuloksena saadaan joko suoria suosituksia, miten tilanteissa kuuluu toimia, tai vaihtoehtoisesti vaadittavaa informaatiota, jonka pohjalta paras toimintatapa pystytään määrittämään. Davenport (2014) korostaa, että pohdittaessa analytiikan tasoja ei ole olennaista keskittyä siihen, mihin luokkaan käytettävä menetelmä sijoittuu, vaan ennemminkin nähdä kokonaiskuva ja ymmärtää, halutaanko analyysillä kuvata ongelmaa, tehdä ennusteita vai ohjata toimintaa.

Tässä tutkimuksessa analysoitaessa Fingridin kunnossapidon siirtymää kohti ennustavaa kuntoperustaista kunnossapitoa tilannetta on syytä tarkastella IoT-datan näkökulmasta. Davenport (2016) lisää perinteisen analytiikan tasoihin IoT-analytiikalle olennaisiksi tasoina diagnostiivisen sekä automaattisen analytiikan. Diagnostiivinen analytiikka voidaan sijoittaa kuvailevan ja ennustavan analytiikan tasojen väliin ja automaattinen analytiikka korkeimmaksi analytiikan tasoksi. IoT-analytiikan kohdalla on Davenportin (2016) mukaan edelleen tavoiteltavaa pyrkiä siirtymään korkeammille tasoille, mutta siirtymä on tavallista analytiikkaa haastavampaa. Kuvailevaa analytiikkaa voidaan IoT-datan kohdalla pitää hyvin samanlaisena, mutta sen merkittävänä haasteena on, että datan suuren määrän takia, päätöksentekijöillä on harvoin aikaa katsoa muodostettuja visualisointeja. Tämän takia kuvaileva analytiikka jää IoT-datan kanssa usein pitkällä aikavälillä unohtuksiin ja hyödyntämättä. (Davenport 2016.)

Diagnostiivinen analytiikka on Gartnerin (n.d.) esittelemä analytiikan taso, jossa datasta pyritään selvittämään, miksi jotain tapahtui. Tähän liittyviä menetelmiä ovat esimerkiksi korrelaatioiden tutkiminen, tiedonlouhinta ja porautuminen (Gartner n.d.). Davenport (2016) korostaa, että kyseinen taso on olennainen IoT-analytiikassa, jossa selvitetään esimerkiksi luokitteluennusteen validiteettia. Tämä voi tarkoittaa esimerkiksi kunnossapidossa sen selvittämistä, miksi jonkin laitteen sanotaan olevan datan pohjalta epäkunnossa. Diagnostiivisella analytiikalla on keskeinen rooli IoT:ssa, sillä useat sensoridatan pohjalta luodut mallit vaativat runsaasti testausta ennen tuotantokäyttöä, jotta paras sovitus mallin

ja liiketoimintaongelman välille voidaan löytää. Vasta tarpeeksi laadukkaan mallin löydyttyä on perusteltua siirtyä ylemmille analytiikan tasoille. (Davenport 2016.)

Ennustava analytiikka voidaan Davenportin (2016) mukaan tunnistaa IoT-datalle tyypillisimmäksi analytiikan muodoksi juuri ennustavan kunnossapidon ansiosta. Ennustavassa kunnossapidossa pyritään tunnistamaan vikatila jatkuvasti, tai säännöllisesti, kerättävällä anturidatalla jo ennen kuin vika pääsee vaikuttamaan koneen toimintaan (Davenport 2016). Davenportin (2016) mukaan ohjaava analytiikka ei IoT-kontekstissa eroa merkittävästi ennustavasta analytiikasta. Keskeisenä erona on se, että ohjaavalla tasolla datan pohjalta annetaan toimintaohje, eikä vain tietoa ennusteesta. Ominaisuus voidaan nähdä sekä positiivisena että negatiivisena. Ohjaavan analytiikan tuloksia on huomattavasti helpompi tulkita, sillä ne kertovat suoraan käyttäjälle mitä tehdä, mutta toisaalta ne voivat näyttäytyä ”mustina laatikkoina”, jolloin käyttäjä ei tiedä mihin suositus perustuu. (Davenport 2016.) Tämä voi hankaloittaa dataohjattua päätöksentekoa, sillä käyttäjien luottamuksen suosittelemien tuottavien analyysien tulee olla korkea. Davenport (2016) korostaa, että parhaat ohjaavat IoT-analytiikkasovellukset selittävät, mihin suositus perustuu.

IoT-dattaa kerääntyy nykyään valtavia määriä, ja liitettäessä yhä useampia laitteita internetiin datan määrä jatkaa kasvamistaan. Davenport (2016) korostaa, että tämä luo yhä suurempaa tarvetta automatisoituun analytiikkaan, jolla tarkoitetaan analytiikan muotoa, jossa ihminen ei ole prosessissa läsnä. Päätökset ja toimenpiteet tehdään tällöin täysin automatisoidusti. Tämä analytiikan muoto ei vielä ole laajamittaisesti millään IoT:ta hyödyntävällä toimialalla erityisen realistista, mutta pidemmällä aikavälillä monet toimijat joutuvat siirtymään siihen datamäärien ja tehtävän analytiikan lisääntyessä. (Davenport 2016.) Automatisoituun analytiikkaan siirtyminen voidaan tehdä pienillä ja ketterillä askeleilla aloittaen yksinkertaisimmista ja helpoimmista prosesseista. Davenport (2016) korostaa, että olennaista ei ole tehdä yksityiskohtaista suunnitelmaa, mihin tasolle organisaation IoT-analytiikka halutaan viedä, vaan ennemminkin luoda olosuhteet jatkuvalla kehitykselle ja tätä kautta mahdollistaa arvonaluontia analytiikasta.

Esitellyt analytiikan ja IoT-analytiikan tasot sisältävät kaikki hyvin samanlaisia vaiheita, vaikka niiden lopputulokset ja käyttötarkoitukset eroavatkin usein merkittävästi toisistaan. Näitä vaiheita voidaan suunnitella ja toteuttaa aiemmin luvussa esiteltujen analytiikan prosessimallien CRISP-DM:n ja visuaalisen analytiikan avulla. Erityisesti CRISP-DM soveltuu yleistettävyytensä ansiosta sovellettavaksi mille tahansa analytiikan tasolle, sillä prosessimalli jättää avoimeksi mitä lopputuloksena käyttöön otettavilla tuotteilla tai prosesseilla tarkoitetaan, ja miten esimerkiksi mallin arviointi tapahtuu. Visuaalisen analytiikan prosessimalli puolestaan soveltuu selkeimmin ennustavaan analytiikkaan ja tätä alemmille analytiikan tasoille. Ohjaavaan ja erityisesti automatisoituun analytiikkaan visuaalinen analytiikka on hankalampi yhdistää, sillä näiden mallien validointi ja testaaminen edellyttävät usein tulosten testaamista käytännössä ennemmin kuin visualisointeja. Esimerkiksi Fingridin kunnossapitomallin kohdalla on haastavaa testata kunnossapidon tarpeellisuuden arvioivaa mallia puhtaasti datan pohjalta tehtävien visualisointien avulla,

vaan arviointi edellyttää konkreettisia toimia, kuten sähköasemalla vierailua ja analysointia.

Vaikka luvussa esitellyissä prosessimalleissa keskitytään vahvasti dataohjatun päätöksenteon mahdollistamiseen teknisestä näkökulmasta ja tarvittavan analytiikkatyön tekoon, ei hankkeesta saatava arvo realisoidu ennen kuin se saadaan vaikuttamaan olemassa oleviin prosesseihin ja toimintatapoihin. Tässä kohdassa keskeisiksi tarkastelukohteiksi nousevat esimerkiksi luvun alussa käsitellyt McAfee & Brynjolfssonin (2012) tunnistamat viisi kriittistä tekijää dataohjatun päätöksenteon onnistumisessa. Tämän lisäksi IoT:n hyödyntäminen arkipäiväisessä toiminnassa ja sen mahdollisuuksien implementoiminen osaksi olemassa olevia prosesseja, tai merkittävämpi prosessien uusiminen, voi vaikuttaa pelottavalta henkilöistä, joiden työkuvaan muutos vaikuttaa (Kranz 2017). Tällöin Kranzin (2017) mukaan korostuvat hankkeeseen liittyvä muutosjohtaminen, käyttäjien osallistuttaminen ja odotusten realisointi. Keskeistä on ymmärtää, että pelkällä teknologisella ratkaisulla ei vielä onnistuta vaikuttamaan olemassa oleviin prosesseihin ja päätöksentekoon.

## 5. KYTKINLAITTEIDEN TUNNUSLUVUT

Tässä luvussa esitetään kirjallisuuden ja Fingridin asiantuntijoiden kanssa käytyjen keskustelujen pohjalta tunnistetut kytkinlaitteisiin liittyvät tunnusluvut. Tunnuslukuja tunnistetaan mittauspaiikkakohtaisesti eli käsitellen erikseen eri antureista saatavat tunnusluvut. Kuten luvussa 3 todettiin, ovat erottimet ja maadoituskytkimet hyvin samanlaisia kytkinlaitteita, joten niiden tunnuslukuja tunnistetaan yhtenä kokonaisuutena. Tunnuslukuja ei enää tässä luvussa tutkita yleistävästi, vaan tarkasteltavaksi näkökulmaksi otetaan Fingridin Kymin asemalla oleva mittausjärjestely. Tämä tarkoittaa, että katkaisijoiden osalta keskitytään moottoriin ja iskunvaimentimeen. Erottimien ja maadoituskytkimien osalta puolestaan tarkasteltavia komponentteja ovat moottori sekä vaihteisto. Lisäksi kaikkien kytkinlaitteiden osalta anturointia tehdään myös ohjauslaatikon olosuhteista.

### 5.1 Katkaisijan, erottimen ja maadoituskytkimen moottorin tunnusluvut

Kymin asemalla sijaitsevien katkaisijoiden toimintamekanismi perustuu viritettyihin jousiin. Dupraz et al. (2006) avaavat prosessia siten, että ohjauksia toteuttavat jouset pystyvät suorittamaan auki-, kiinni- ja aukiohjauksen omalla varastoidulla energiallaan. Energiatasojen tippuessa liian alhaiseksi tarvitsee jousia kuitenkin virittää riittävän viritystilan saavuttamiseksi. Lepotilassa energia on varastoituna kiinnijouseen. Ohjauksien yhteydessä energiatason tippuessa määritetyn rajan alapuolelle, mekanismissa käynnistyy moottori, joka virittää kiinnijousta. (Dupraz et al. 2006.) Moottorin toimimattomuus voi johtaa jousen viritystilan menettämiseen, jolloin ohjaukset eivät enää onnistu komenosta. Kymissä olevassa mittausasettelussa katkaisijan jousen viritystä suorittavaan moottoriin liittyen kerätään moottorin virran käyttöä sekä sen toiminnasta syntyvää ääntä.

Moottorin virtaprofiilin (engl. *current signature*) analysointi on kunnonvalvontamenetelmä, jonka avulla voidaan tunnistaa useita erilaisia moottorin vikatilanteita. Lau & Ngan (2010) kertovat, että analyysin idea perustuu siihen, että vikatilanteet ovat useimmiten peräisin toimintamekanismista tapahtuvassa virheessä, joka puolestaan vaikuttaa moottorin virrankäyttöön. Usein mekaaninen vika ilmenee tarpeena käyttää enemmän virtaa saman operaation suorittamiseen, jolloin virtaprofiili muuttaa muotoaan. Iorgulescu & Beloiu (2012) nostavat esille, että suurin osa moottorien virtaprofiilien analysointiin liittyvästä tutkimuksesta on keskittynyt vaihtovirtamoottoreihin, eikä tasavirtamoottoreihin. Tämä luo haastetta Kymin laitteistojen analysointiin, sillä kyseiset kytkinlaitteet on varustettu tasavirtamoottoreilla.

Tasavirtamoottorien virtakäyrien analysointi poikkeaa vaihtovirtamoottorien analysoinnista, sillä tasavirtamoottoreille ei pystytä samalla tavalla laskemaan tunnuslukuja kuin

aaltomuotoiselle vaihtovirralla. Tasavirtamoottorien tuottamat virtakäyrät ovat hyvin laite- ja käyttötapauskohtaisia. Esimerkiksi erottimien ja katkaisijoiden moottorien virtakäyrät eroavat toisistaan, mutta ovat saman laiteryhmän sisällä vertailukelpoisia. Vaikka tunnuslukuja, joiden perusteella olisi mahdollista paikantaa vian sijainti, ei olekaan löydettävissä, voidaan virtakäyrää hyödyntää vikatilän tunnistamiseen vertaamalla virtakäyriä keskenään. Muista saman laitetyypin virtakäyristä merkittävästi poikkeava virtakäyrä voidaan epäillä olevan peräisin viallisesta laitteesta, joka edellyttää korjausta. Virtakäyriä verrattaessa on huomioitava mekaanisten laitteiden normaali kuluminen. Uuden moottorin ja 30 vuotta käytössä olleen moottorin virtakäyrien ei voida olettaa käyttäytyvän samalla tavalla, vaikka molemmat olisivat täysin toimintakykyisiä. Tämä on otettava huomioon analyysissä ja rajattava vertailu esimerkiksi vain viime aikaisiin mittauksiin tietyltä kytkinlaitteelta.

Signaalikäyrien vertaamiseen voidaan hyödyntää signaalinkäsittelyn dynaamista aikasovitusalgoritmia, joka mahdollistaa eripituisten aikasarjojen vertailun käyrien muotojen perusteella. Keogh & Pazzani (1999) esittävät, että dynaamisen aikasovituksen etu perinteiseen euklidiseen etäisyyteen, jossa lasketaan kahden samalla ajanhetkellä olevan pisteen erotusta, verrattuna on sen mukautuvuus aikasarjojen epäsynkronisuuteen, ajan skaalautumiseen ja amplitudien eroavaisuuteen. Dynaamisen aikasovitusalgoritmin esittäminen matemaattisesti on hankalaa, mutta se voidaan ohjelmakoodina kirjoittaa melko yksinkertaisella funktiolla, joka ottaa syötteenään kaksi listaa ja palauttaa näiden välisen dynaamisen aikasovitusetäisyyden. Algoritmi on laskennallisesti hyvin raskas, joten sen käyttämiseen suurilla datamäärillä on suhtauduttava varauksella. Funktion toteutukseen palataan tarkemmin luvussa 6.1.

Moottorin virrankäytöstä voidaan päätellä ohjaustapahtuman suorittamiseen kulunut aika eli ohjauksen kesto. Katkaisijan osalta tätä kutsutaan viritysajaksi. Ohjauksen kestot voivat Laitisen & Tammen (2018) mukaan vaihdella jopa moninkertaisiksi riippuen tarkasteltavasta laitteesta ja vallitsevista sääoloista. Esimerkiksi erityisen kylmissä olosuhteissa ohjaukset voivat kestää poikkeuksellisen pitkään. Kestojen vertaaminen on siis mielekästä esimerkiksi tilanteessa, jossa päivän aikana suoritetaan samanlaisilla laitteilla useita ohjauksia. Mikäli ohjausaikoja haluttaisiin verrata yksittäisten ohjausten osalta, olisi luotava malli, joka huomioi mm. sääolosuhteet ja laitteiston iän tyypillisen ohjausajan määrityksessä.

Vikatilojen tunnistaminen ohjausaikojen perusteella tukeutuu olettamukseen, että vikaantuessaan laitteen ohjausaika pitenee suhteessa vastaaviin normaalisti operoiviin systeemeihin. Esimerkiksi katkaisijan kohdalla tämä näkyisi viritysajan pidentymisellä, jolloin jokin komponentti hidastaa prosessia ja vaatii huoltoa. (Laitinen & Tammi 2018.) Ohjausajat saadaan määritettyä moottorin virtakäyrästä laskemalla ohjaustapahtuman alkuvirtapiikin ja loppuvirtapiikin väliin jäävä aika.

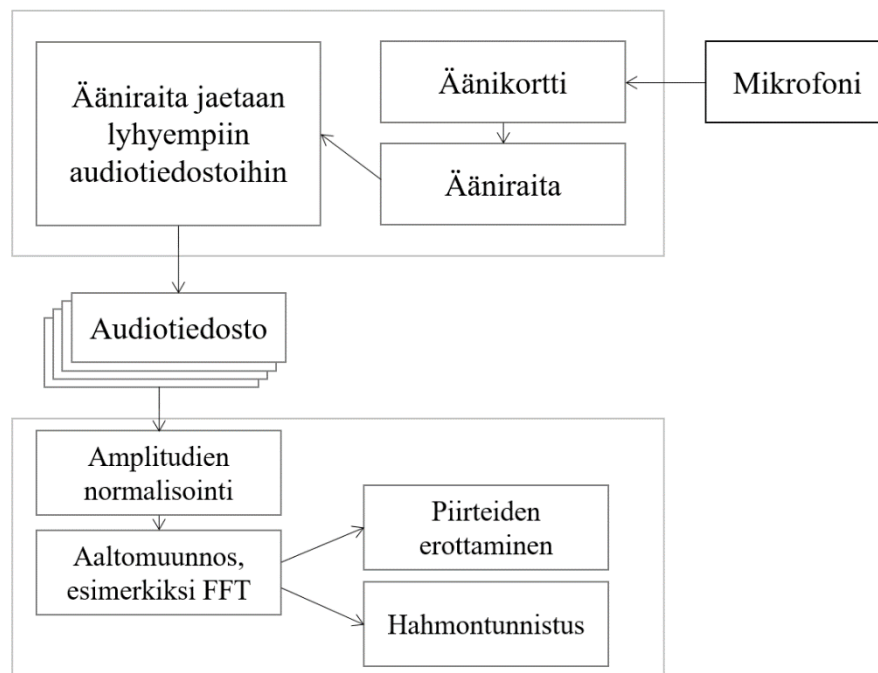
Virtakäyrästä voidaan laskea myös ohjauksen aikana tapahtuvaa virrankulutusta ottamalla summaintegraali (Laitinen & Tammi 2018). Integraalilla saadaan määritettyä virtakäyrän ja x-akselin väliin jäävä alue, joka vastaa siirtynyttä varausta tarkastellussa aikaikkunassa. Varauksen siirtyminen voidaan matemaattisesti määrittää seuraavasti (Young & Freedman 2003):

$$q = \int_0^T I(t) dt, \quad (1)$$

jossa  $q$  tarkoittaa siirtynyttä varausta,  $T$  päättymisaikaa,  $t$  yksittäistä ajanhetkeä ja  $I$  virtaa.

Laskemalla varauksen siirtyminen eli virrankulutus voidaan tehdä johtopäätöksiä laitteiston tilasta, sillä vikaantunut laite kuluttaa todennäköisesti enemmän virtaa kuin hyvässä kunnossa oleva laitteisto.

Moottorin äänen analysointi perustuu moottorin lähettävällä sijaitsevan mikrofonin nauhoittaman äänitiedoston prosessoimiseen ja tulkitsemiseen. Moottoriäänien analysoimisen etuna on sen anturin helppo asennettavuus, sillä mikrofoni voidaan liittää jälkikäteen mitattavaan laitteeseen. Merkittävänä haasteena puolestaan on oikean akustisen signaalin erottaminen, sillä ympäristön melu ja muiden laitteiden toimintääänet tallentuvat myös. (Głowacz & Głowacz 2017.) Tämä tarkoittaa, että signaali vaatii merkittävää prosessointia ennen kuin sitä voidaan hyödyntää. Cho (2018) nostaa esille, että moottorin liittyvää tieteellistä mittaamista ja analyttistä tutkimusta on tehty melko vähän. Tämä voi liittyä esimerkiksi moottorityyppien runsauteen ja äänilähteiden monimutkaisuuteen (Cho 2018). Äänisignaalin analysoinnin vaiheita ja käsittelyä on esitetty kuvassa 8.



**Kuva 8.** Audiosignaalin analysointi (mukaillen lähdettä Glowacz 2016)

Tunnuslukujen osalta keskeinen vaihe on piirteiden erottaminen. Vaihe ei kuitenkaan ole itsenäinen, vaan se on tiukasti riippuvainen edellä tehtävästä aaltomuunnoksesta. Valittu



aaltomuunnos vaikuttaa siihen, mitä piirteitä havaitusta signaalista pystytään erottamaan ja millaisia numeraalisia arvoja tunnusluvut saavat. Viimeisessä vaiheessa tapahtuvalla piirteiden erottamisella voidaan tarkoittaa esimerkiksi spektrianalyysin tuottamista, ja hahmontunnistuksella uuden äänisignaalin vertaamista aiemmin saavutettuihin tuloksiin.

Aaltomuunnoksen tarkoituksena on muuttaa analoginen signaali digitaaliseen muotoon. Tämä onnistuu tehokkaasti esimerkiksi käyttäen FFT-menetelmää (engl. *Fast Fourier Transform*), joka verrattuna perinteiseen Fourierin muunnokseen on huomattavasti nopeampi laskea (Nohynek & Lumme 2004). Siirryttäessä digitaaliseen muotoon tavoitteena on päästä aikatasosta taajuustasoon, jotta eri lähteistä peräisin olevat taajuuskomponentit voidaan erotella toisistaan. Nohynek & Lumme (2004) määrittävät, että Fourier-sarjojen avulla voidaan signaalista tuoda esille eri amplitudisten ja taajuuksien harmonisten signaalien summa. FFT-menetelmällä saavutettavan värähtelyspektrin avulla voidaan mahdollistaa yksittäisten laitteen komponenttien monitorointi. Tämä kuitenkin edellyttää tarkkoja tietoja tarkasteltavan koneen mekaanisesta rakenteesta, jotta koneen vikataajuuksien tunnistaminen on mahdollista. Spektrien ja spektrogrammin analysointi eli spektrivalvonta edellyttää tulkitsijalta merkittävää kokemusta tarkasteltavasta koneesta ja usein myös merkittäviä määriä kerättyä dataa. (Nohynek & Lumme 2004.) Kymin asemalta on kerätty dataa vasta melko lyhyen ajanjakson ajan, eikä laitteistossa ole tapahtunut tänä aikana vikatilanteita. Tämän takia spektrivalvonta, jossa tunnistettaisiin vian sijainti, ei ole tälle tutkimukselle relevanttia.

Wang et al. (2013) tutkivat tasavirtamoottorin vian tunnistusta äänisignaalin avulla ja hyödynsivät aaltomuunnoksessa FFT-menetelmää. Moottoriäänien mekaaniseen analyysiin liittyvät äänet voidaan jakaa kolmeen tyyppiin: Elektromagneettinen melu, joka syntyy moottorin käynnistyessä väännöstä tuottaen värinää ja ääntä. Mekaaninen melu, joka syntyy laakerien ja moottorien hiilen perusteella. Tähän vaikuttaa käytetyt materiaalit ja kokoamisen laatu. Kolmantena äänityyppinä tunnistetaan ilmanvaihtoon liittyvä melu eli moottoria viilentävästä tuulettimesta syntyvät äänet. (Wang et al. 2013.) Aaltomuunnoksen avulla saadun värähtelyspektrin perusteella Wang et al. (2013) ehdottavat taulukossa 2 esitettyä jaottelua värähtelytaajuuksien äänilähteille.

Taajuusalue (selkeät piikit)	Äänilähde	Mahdollinen merkitys
50-500 Hz	Ilmanpaineesta syntyvät äänet	Laitevika, poikkeama toimintamekanismeissa
500-1000 Hz	Resonanssiäänet	Elektromagneettisen värinän harmoniset resonanssitaajuudet
1-2 kHz	Laakerien akselien ääni ja värinä	Moottorin epäpuhdas toiminta
2-5 kHz	Laakerien ääni ja värinä	Laakerien heikko kunto tai sopimattomuus

**Taulukko 2.** Moottorin taajuuspiikkien merkitykset Wang et al. (2013) mukaan

Vikatilanteiden tunnistamiseen puhtaasti taajuusalueiden pohjalta on kuitenkin suhtauttava varauksella, sillä moottorit ja niiden sijainnit ovat hyvin erilaisia keskenään. Esimerkiksi ahtaassa suljetussa tilassa sijaitsevaan moottoriin voi helposti syntyä resonanssiipiikkejä ympäristön seurauksena. Yleispätevien indikaattorien puuttuessa on perusteltua hakea audiosignaaleille ominaisia tunnuslukuja, kuten spektriin liittyviä piirteitä.

Tzanetakis & Cook (2002) esittelevät audiosignaaleille ominaisia piirteitä, joiden pohjalta voidaan tehdä johtopäätöksiä ääneen liittyen. Esitellyt piirteet ovat STFT-muunnoksen (engl. *short time Fourier transform*) pohjalta laskettuja tunnuslukuja, jotka kuvaavat signaalista muodostettua spektriä. Spektrin tunnusluvuille ei ole olemassa yleistettyjä erityyppisiä laitteita kattavia raja-arvoja, vaan ne on määritettävä erikseen tarkasteltaville laitteille. (Tzanetakis & Cook 2002.) Tämä onnistuu keräämällä dataa laitteiden normaalisti toiminnasta ja tunnistamalla näistä tyypillinen vaihteluväli. Tämän jälkeen tunnuslukuja analysointiin voidaan käyttää perinteisiä koneoppimisen menetelmiä. Tzanetakis & Cook (2002) tunnistavat audiosignaaleista laskettaviksi tunnusluvuiksi seuraavat: spektrin keskipiste, spektrin vinous, nollanylitystaajuus ja MFCC (*Mel-frequency Cepstral Coefficients*).

Spektrin keskittyneisyys (engl. *spectral centroid*) kuvaa spektrin painopisteen sijaintia. Keskittyneisyydellä voidaan numeraalisesti kuvata spektrin muotoa, sillä esimerkiksi korkeampi keskittyneisyys-arvo tarkoittaa näkyvämpiä kuvioita spektrogrammissa korkeilla taajuuksilla. (Tzanetakis & Cook 2002.) Spektrin keskittyneisyys saadaan laskettua kaavalla (Tzanetakis & Cook 2002):

$$C_t = \frac{\sum_{n=1}^N M_t[n] * n}{\sum_{n=1}^N M_t[n]}, \quad (2)$$

jossa  $M_t[n]$  on Fourier-muunnoksen suuruus,  $t$  kuvaa käsiteltävää aika-kehystä,  $n$  taajuuskomponenttia ja  $N$  aika-kehysten lukumäärää.

Spektrin vinous (engl. *spectral rolloff*) kertoo taajuuden, jonka alapuolelle sijoittuu 85 % spektrin tarkastellun kehyksen energiasta. Spektrin vinoutta käytetään keskittyneisyyden ohella kuvaamaan spektrin muotoa. (Tzanetakis & Cook 2002.) Vinous saadaan määritettyä matemaattisesti kaavalla (Tzanetakis & Cook 2002):

$$\sum_{n=1}^{R_t} M_t[n] = 0,85 * \sum_{n=1}^N M_t[n], \quad (3)$$

jossa  $R_t$  tarkoittaa spektrin vinoutta eli viittaa yksittäiseen taajuuteen.

Nollanylitystaajuus (engl. *time domain zero crossings*) on tunnusluku, joka kertoo, kuinka monta kertaa audiosignaali ylittää koordinaatiston x-akselin, eli kuinka useasti lukuarvon etumerkki vaihtuu (Tzanetakis & Cook 2002). Nollanylitystaajuus määritetään matemaattisesti kaavalla (Tzanetakis & Cook 2002):

$$Z_t = \frac{1}{2} \sum_{n=1}^N |sign(s[n]) - sign(s[n-1])|, \quad (4)$$

jossa  $Z_t$  tarkoittaa nollanylitystaajuutta,  $s[n]$  signaalin  $s$  pistettä  $n$  ja  $sign$  funktiota, joka palauttaa positiivisille arvoille luvun 1 ja negatiivisille arvoille luvun 0.

MFCC-arvot ovat tunnuslukuja, jotka ovat yleisesti käytössä erityisesti puheentunnistuksessa. MFC-piirteissä äänten taajuudet suhteutetaan tapaan, jolla ihminen kuulee ääntä. Tämä onnistuu mel-asteikon avulla. (Memon et al. 2009.) Muunnos taajuus-asteikosta mel-asteikkoon onnistuu seuraavalla kaavalla (Memon et al. 2009):

$$f_{mel} = 2595 \log_{10}(1 + \frac{f}{700}), \quad (5)$$

jossa  $f_{mel}$  viittaa mel-arvoon ja  $f$  taajuuteen.

Vaikka MFCC-arvojen laskeminen onkin perinteisesti ollut puheentunnistuksessa hyödynnettävä menetelmä, mm. Nelwamondo & Marwala (2006) sekä Benkedjouh et al. (2017) hyödyntävät tutkimuksissaan MFCC-arvoja erilaisiin viantunnistustehtäviin. MFCC-arvojen laskeminen voidaan jakaa kuuteen eri vaiheeseen (Memon et al. 2009):

1. Signaali jaetaan kehyksiin ja näille lasketaan tehospektri
2. Määritetään halutun kokoinen suodatinpankki Mel-asteikon avulla tasaisilla kolmion muotoisilla kaistanpäästösuodattimilla
3. Jokaiselle suodattimelle lasketaan sen alle jäävä energia
4. Lasketaan DCT-arvot (*Discrete Cosine Transformation*) suodattimien energioille.

Lopputulokseksi saadaan yhtä monta MFC-arvojoukkoa kuin toisessa vaiheessa valittiin suodattimia. Näistä nollatta termiä ei usein huomioida sen erottelukyvyn heikkouden takia. Tämän jälkeen käytetään valittua määrää ensimmäisiä MFC-arvojoukkoja, sillä loppupään kertoimet kuvaavat korkeita taajuuksia, jotka yleisesti pitävät sisällään vain vähän hyödynnettävissä olevaa informaatiota. (Memon et al. 2009) Käytettävien arvojen määrä riippuu käyttötarkoituksesta, sillä puheentunnistuksessa käytetään usein 13 ensimmäistä arvojoukkoa, kun taas Memon et al. (2009) huomasivat vain viiden ensimmäisen suodattimen käyttämisen riittävän musiikkigenren tunnistamiseen.

Tunnuslukujen toimivuus vikatilanteiden tunnistamiseen on hyvin tilannekohtaista ja vaatii runsaasti dataa toimivuuden varmentamiseksi. Usein vasta todelliset vikatilanteet paljastavat, miten häiriöt systeemissä heijastuvat muodostettuun spektriin. Nohynek & Lumme (2004) kertovat, että spektrivalvonta perustuu hälytysrajaspektrien hyödyntämiseen. Tällöin mittauspisteelle, eli tarkasteltavalle taajuusalueelle luodaan oma hälytysraja. Hälytysrajaspektrit luodaan edustavan mittauksen perusteella eli tilanteesta, jossa koneen tiedetään olevan hyvässä kunnossa. Edustavan mittauksen pohjalta määritetään tarvittavat väljyydet, jossa arvot saavat liikkua, ennen kuin hälytysrajaspektri saavute-

taan. (Nohynek & Lumme 2004.) Esitellyistä spektrin tunnusluvuista on myös huomiotava, että ne koskevat spektrin yksittäistä ikkunaa. Tällöin koko signaalille saadaan valittua ikkunamäärää vastaava lukumäärä tunnuslukuja. Kahden tunnuslukusarjan vertaaminen keskenään edellyttää puolestaan omanlaisiaan tilastollisia menetelmiä.

## 5.2 Katkaisijan iskunvaimentimen tunnusluvut

Katkaisijan ohjaus tapahtuu viritetyn jousen avulla, jonka liike pitää ohjauksen tapahduttua pystyä vaimentamaan. Tämä tapahtuu iskunvaimentimen avulla, joka hidastaa mekanismin liikettä, kunnes se saavuttaa lepotilan. Tehdyssä kirjallisuusselvityksessä huomattiin, että katkaisijoiden iskunvaimentimelle on tehty kaiken kaikkiaan melko vähän tutkimusta ja se on keskittynyt pääsääntöisesti esimerkiksi iskunvaimentimien suunnitteluun tai väliaineeseen. Erityisesti sähköasemien katkaisijoihin keskittynyttä iskunvaimentimiin liittyvää tutkimusta ei onnistuttu löytämään.

Katkaisijan iskunvaimentimen toimintaan liittyvä anturi Kymin kytkinasemalla olevassa mittaustilanteessa on katkaisutapahtuman aikaisen iskunvaimentimen toiminnan ääntä nauhoittava kontaktimikrofoni. Tämä aiheuttaa selkeitä rajoituksia mahdollisiin tunnuslukuihin. Esimerkiksi Heinisen et al. (2016) käyttämät iskunvaimentimen kuntoa kuvaavat voima-siirtymä käyrä tai iskunvaimentimen kammion paine eivät ole mahdollisia hyödynnettäviä tunnuslukuja tällä mittaussasettelulla. Mikrofonimittauksesta saadaan tuotettua iskunvaimentimen toiminnan äänispektri. Kirjallisuusselvityksen perusteella iskunvaimentimen tuottaman äänen analysointia ei ole juurikaan tutkittu, vaan värähtelyanalyseissa on pyritty lähinnä tunnistamaan vikatiloja signaalinkäsittelyn menetelmin. Tämä tarkoittaa, etteivät tunnistettavat tunnusluvut ole erityisesti spesifioituja nimenomaan iskunvaimentimen analysointiin, vaan ennemminkin värähtelysignaalin analysointiin ja poikkeuksien tunnistamiseen. Nohynek & Lumme (2004) nimeävätkin värähtelyvalvonnan aikatazon tunnusluvuiksi seuraavaksi esiteltävät tehollisarvon, huippuarvon, huipusta huippuun –arvon ja huippukertoimen.

Värähtelysignaalin tehollisarvo (engl. *root mean square*) on tunnusluku, jonka avulla voidaan arvioida värähtelyn voimakkuutta. Leboldin et al. (2000) mukaan tehollisarvo on hyvä suure mitattaessa yleistä äänitasoa, mutta sen avulla ei ole mahdollista paikantaa vian sijaintia. Tehollisarvo voi kuitenkin osoittautua hyödylliseksi, mikäli tavoitteena on tunnistaa, toimiiko laite normaalisti vai onko kyseessä vikatila. (Lebold et al. 2000.) Tehollisarvo voidaan laskea seuraavasti (Lebold et al. 2000; Večeř et al. 2005):

$$s_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N (s_i^2)}, \quad (6)$$

jossa  $s_{rms}$  on värähtelysignaalin tehollisarvo,  $N$  on signaalin  $s$  datapisteiden määrä, ja  $s_i$  on signaalin  $s$   $i$ :s havaintopiste.

Huipusta huippuun -arvo (engl. *peak-to-peak value*) on tunnusluku, jota käytetään lähinnä muiden värähtelyyn liittyvien tunnuslukujen laskemiseen. Nohynek & Lumme (2004) määrittävät huipusta huippuun -arvon kuvaavan mittauksen suurimman ja pienimmän arvon erotusta. Tätä voidaan hyödyntää värähtelyn ääripäiden etäisyyden vertailussa (Nohynek & Lumme 2004). Matemaattisesti huipusta huippuun – arvo esitetään seuraavasti:

$$S_{peak-peak} = \max(s) - \min(s), \quad (7)$$

jossa  $S_{peak-peak}$  on huipusta huippuun –arvo ja  $s$  tarkasteltava signaali.

Huipukkuus (engl. *kurtosis*) on tunnusluku, joka kuvaa sitä, onko värähtelysignaalin amplitudijakauma tasainen vai piikikäs verratessa sitä normaalijakaumaan (Lebold et al. 2000). Večeř et al. (2005) kertovat, että värähtelysignaalin sisältäessä korkeita piikkejä myös sen amplitudijakaumaan kuvautuu piikkejä. Tällöin voidaan olettaa, että tämän tyyppiset piikit ovat peräisin vioittumisesta. Toisin sanoen viallisen laitteen huipukkuus saa korkeamman arvon kuin hyväkuntoisen laitteen. Huipukkuus voidaan matemaattisesti määrittää seuraavasti (Lebold et al. 2000; Večeř et al. 2005):

$$Kurt = \frac{N \sum_{i=1}^n (s_i - \bar{s})^4}{(\sum_{i=1}^n (s_i - \bar{s})^2)^2}, \quad (8)$$

jossa  $Kurt$  tarkoittaa huipukkuutta,  $N$  on signaalin  $s$  havaintopisteiden määrä tarkastelussa aikahorisontissa, ja  $s_i$  on  $i$ :s havaintopiste signaalille  $s$ .

Huippukerroin (engl. *crest factor*) on tunnusluku, joka saadaan jakamalla huippuarvo tehollisarvolla (Lebold et al. 2000; Večeř et al. 2005). Večeřin et al. (2005) mukaan huippuarvo on signaalin maksimiarvo tarkastellulta aikaväliltä. Tätä tunnuslukua käytetään apuna myös muiden tunnuslukujen laskentaan (Večeř et al. 2005). Huippukertoimen etuna on se, että sen avulla voidaan huomata jo hyvin aikaisessa vaiheessa vikaantumisia, sillä se huomioi sekä huippuarvon kasvun että tehollisarvon pienenemisen, jotka molemmat näkyvät huippukertoimen kasvamisena (Lebold et al. 2000). Huippukerroin voidaan matemaattisesti esittää kaavalla (Lebold et al. 2000; Nohynek & Lumme 2004):

$$CF = \frac{S_{peak}}{S_{rms}}, \quad (9)$$

jossa  $CF$  on huippukerroin,  $S_{peak}$  on huippuarvo, ja  $S_{rms}$  kuvaa tehollisarvoa. Huippukertoimen avulla havaitaan muutoksia signaalin muodossa, jotka saattavat johtua esimerkiksi kulumisesta tai vaihteiston hammasrattaan rikkoontumisesta.

### 5.3 Erottimen ja maadoituskytkimen vaihteiston tunnusluvut

Vanraj et al. (2017) nostavat esille vaihteiston keskeisen roolin nykyaikaisten laitteistojen toiminnassa. Yleisesti teollisuuslaitteissa jopa 80 % voimansiirtoon liittyvistä vikaantu-

misista johtuu vaihteiston rikkoontumisesta, joten vaihteiston toimivuus ja kunnonvalvonta ovat nousseet keskeiseen rooliin toimivuuden varmistuksessa (Li et al. 2011). Vaihteistojen vianetsinnän kannalta värähtelyä pidetään yleisesti keskeisimpänä komponenttina ja merkittävä määrä tutkimusta onkin keskittynyt värähtelysignaalin mittaamiseen, analysointiin ja kvantifiointiin (Vanraj et al. 2017).

Erottimen vaihteistolle voidaan värähtelysignaalista laskea samat yleiset signaalinkäsittelyn tunnusluvut kuin katkaisijan iskunvaimentimelle. Näitä tunnuslukuja ovat huipusta huippuun –arvo, tehollisarvo, huipukkuus ja huippukerroin (Lebold et al. 2000; Decker 2002; Večeř et al. 2005). Edellä mainitut tunnusluvut ovat mekaanisten laitteiden tyypillisimpiä tunnuslukuja, jotka ovat melko yksinkertaisesti laskettavissa äänen värähtelysignaalista, joita myös Fingridin sähköasemalla olevat mikrofonit mittaavat. Tämän lisäksi mm. Lebold et al. (2000), Decker (2002) sekä Večeř et al. (2005) esittelevät useita vaihteiston tunnuslukuja, joiden laskeminen edellyttää lisämittauksia Kymin sähköaseman mittaustilanteesta ja saatavien signaalien jatkojalostusta. Näitä tunnuslukuja ovat energiasuhde, FM0, FM4 ja NA4\*. Vaihteistoon liittyvistä tunnusluvuista voidaan kirjallisuusselvityksen pohjalta huomata, että eri kirjoittajat esittävät niitä eri muodoissa ja eriävillä laskentatavoilla. Esimerkiksi signaalityyppien määrittämisessä huomioitavat seikat riippuvat kirjoittajasta (Decker 2002; Večeř et al. 2005; Sait & Sharaf-Eldeen 2011).

Večeřin et al. (2005) mukaan vaihteiston tunnuslukujen laskennassa käytetään yleisesti kolmea signaalityyppiä: raakasignaalia (engl. *raw*), jäännössignaalia (engl. *residual*) ja erosignaalia (engl. *difference*). Raakasignaalilla viitataan suoraan laitteistosta mitattuun käsittelemättömään signaaliin. Jäännössignaali puolestaan kuvaa aikasykronisesti keskiarvoistettua raakasignaalia, josta on poistettu akseleista syntyvät taajuudet, rasteritaajuudet sekä näiden kerrannaiset. Rasteritaajuudella (engl. *mesh frequency*) viitataan taajuuteen, jolla hammasrattaat osuvat toisiinsa. Rasteritaajuuden laskeminen edellyttää hammaspyörän kierrosnopeuden ja hampaiden määrän tietämistä. Suodatettaessa jäännössignaalista ensimmäinen sivukaistale saadaan erosignaali. (Lebold et al. 2000; Večeř et al. 2005.)

Energiasuhde (engl. *energy ratio*) on tunnusluku, jonka muuttuminen perustuu olettaukseen, että laitteiston kuluessa energia siirtyy varsinaisesta värähtelyn signaalista erosignaaliin (Večeř et al. 2005; Sait & Sharaf-Eldeen 2011). Večeř et al. (2005) korostavat, että energiasuhteella pystytään erinomaisesti havaitsemaan suuria vikatiloja, jotka vaikuttavat useisiin hammasrattaan hampaisiin. Energiasuhde voidaan matemaattisesti määrittää seuraavasti (Decker 2002; Sait & Sharaf-Eldeen 2011):

$$ER = \frac{RMS_{dif}}{RMS}, \quad (10)$$

jossa  $RMS$  kuvaa raakasignaaliin laskettua tehollisarvoa ja  $RMS_{dif}$  erosignaalin tehollisarvoa.

FM0 on huippukerrointa muistuttava tunnusluku, joka vertaa huipusta huippuun –arvoa rasteritaajuuksien tehollisarvojen summaan. FM0 tunnuslukua käytetään havaitsemaan merkittäviä vikatilanteita, sillä suuret hammasvioletumiset kasvattavat huipusta huippuun arvoa, mutta eivät vaikuta rasteritaajuuksiin (Lebold et al. 2000). FM0 voidaan matemaattisesti määrittää Deckerin (2002) mukaan seuraavasti:

$$FM0 = \frac{S_{peak-peak}}{\sum_{i=1}^N RMS(f_i)}, \quad (11)$$

jossa  $S_{peak-peak}$  kuvaa raakasignaalin huipusta huippuun –arvoa,  $N$  rasteritaajuuden kerrannaisten määrää,  $RMS$  tehollisarvoa ja  $f_i$  rasteritaajuutta. Večeř et al. (2005) ja Lebold et al. (2000) puolestaan käyttävät tehollisarvon summan tilalla amplitudien summaa, jolloin kaava saadaan muotoon:

$$FM0 = \frac{S_{peak-peak}}{\sum_{i=1}^N A(f_i)}, \quad (12)$$

jossa  $A$  tarkoittaa rasteritaajuuden kerrannaisen amplitudia.

FM4 tunnusluku perustuu oletukseen, että hyväkuntoisen vaihteiston signaali muistuttaa Gaussista amplitudijakaumaa ja huonokuntoisen vaihteiston, jolla on yksittäinen vioittunut hammasratas, puolestaan muodostaa eriävän signaalin merkittävän korkeilla huipuilla tai jatkuvilla piikeillä. (Večeř et al. 2005.) Tällöin jakaumat eroavat merkittävästi toisistaan ja tunnusluku kasvaa. Mikäli useampi kuin yksi ratashammas on vioittunut, data on jakautunut tasaisemmin, eikä tunnusluvusta voida aina tunnistaa poikkeamaa. Tällöin vikatila voidaan kuitenkin havaita huipukkuuden pienenemisellä. (Večeř et al. 2005.) FM4 voidaan matemaattisesti määrittää seuraavasti (Decker 2002; Večeř et al. 2005):

$$FM4 = \frac{N \sum_{i=1}^n (d_i - \bar{d})^4}{(\sum_{i=1}^n (d_i - \bar{d})^2)^2}, \quad (13)$$

jossa  $d_i$  kuvaa  $i$ :ttä vertailusignaalin  $d$  datapistettä ja  $N$  datapisteiden määrää.

NA4\* tunnusluku kehitettiin Deckerin (2002) mukaan korjaamaan FM4 tunnusluvun puute havaita useampaan hampaaseen leviävää vikatilaa. Vertaamalla jäännössignaalia hyväkuntoiseksi tiedetyn vaihteiston jäännössignaaliin, saadaan tunnusluku kasvamaan vian pahentuessa. Tällöin vikatilan tunnistamisen lisäksi voidaan tarkkailla vian kehittymistä laitteistossa. (Decker 2002; Sait & Sharaf-Eldeen 2011.) Matemaattisesti NA4\* voidaan määrittää seuraavalla tavalla (Decker 2002; Večeř et al. 2005; Sait & Sharaf-Eldeen 2011):

$$NA4^* = \frac{N \sum_{i=1}^n (r_i - \bar{r})^4}{(var(r_{ok}))^2}, \quad (14)$$

jossa  $N$  on datapisteiden määrä,  $r_i$  on jäännössignaalin  $r$   $i$ :s datapiste,  $\bar{r}$  jäännös-signaalin keskiarvo ja  $\text{var}(r_{ok})$  vertailukohteen toimivan hyväkuntoisen vaihteiston jäännössignaalin varianssi.

## 5.4 Ohjausyksikön tunnusluvut

Ohjausyksikön tunnusluvut ovat mitattavista kohteista yksinkertaisempia ja vaativat vähiten esiprosessointia ja laskentaa ollakseen hyödynnettävissä muodossa. Kymen asemalla ohjausyksikköihin on asennettu lämpötila- ja ilmankosteusanturit, jotka tekevät mittauksia tasaisin määritellyin väliajoin myös silloin kun kytkinlaitteilla ei tehdä ohjauksia. Laitinen et al. (2018) korostavat, että ohjausyksikön lämpötilalla ja ilmankosteudella on selkeä vaikutus ohjaimen oikeanlaiseen toimintaan sen elinkaaren aikana. Tunnuslukujen yksinkertaisuudesta huolimatta, ei niiden ympärille rakennettava analytiikka ole täysin suoraviivaista. Vertailukohde ja raja-arvot on mietittävä tarkasti.

Lämpötilan tulisi erityisesti lämpimillä keleillä korreloida ulkoilman lämpötilan kanssa, sillä ohjausyksiköt sijaitsevat sähköasemilla ulkona suojanaan vain ohjausyksikön kotelo. Tällöin merkittävät poikkeamat ulkoilman lämpötilan ja ohjausyksikön lämpötilan välillä voisivat viestiä poikkeustilasta, kuten starttimoottorin liiallisesta lämpenemisestä. Tällä hetkellä käytössä ei kuitenkaan ole sähköasemalta mitattua ulkolämpötilaa. Ohjausyksiköt on varustettu lämmittimillä, jonka ansiosta ne pystyvät toimimaan kovissakin pakkasissa. Kylmässä lämpötilassa ohjausyksikön lämpötilan tippuminen poikkeuksellisen alhaiseksi voi kertoa lämmityslaitteiston rikkoutumisesta, ja täten mittaaminen mahdollistaa reagoinnin vikatilanteeseen. Ohjausyksikön lämpötilaa voidaan ulkoilman olosuhteiden lisäksi analysoida myös suhteessa muiden ohjausyksikköjen lämpötilaan. Mikäli yksittäisen ohjausyksikön olosuhteet poikkeavat merkittävästi muista samanlaisista ohjausyksiköistä voi kyse olla esimerkiksi avonaiseksi jääneestä luukusta tai rikkoutuneesta lämmityslaitteesta.



## 6. TUNNUSLUKUJEN MÄÄRITYS

Tässä luvussa tunnistetaan viidennessä luvussa määritettyjä tunnuslukuja Fingridin Kymin asemalta kerätystä anturidatasta. Jokaiselle tunnusluvulle esitetään python-ohjelmointikielen (versio 3.6.3) avulla, miten se on mahdollista laskea Kymin asemalta kerätystä datasta. Mikäli tunnuslukuna saadaan arvojoukko, visualisoidaan tätä joukkoa histogrammin avulla. Yksittäisten tunnuslukujen kohdalla suoritetaan laskennat viidelle havainnolle, esimerkiksi viidelle erottimen vaihteistosta saadulle äänitiedostolle, ja nämä tulokset visualisoidaan.

Esimerkkikoodissa lähdetään liikkeelle tilanteesta, jossa tiedostot on ladattu lokaalille koneelle pilvipalvelussa olevassa tiedostomuodossa. Signaalit ovat siis suoraan asemalta mitattuja raakasignaaleja, joille ei ole vielä tehty esiprosessointia. Tässä työssä ei oteta kantaa tiedostojen oikeellisuuteen, eli virhekäsittelyä väärin tiedostojen varalta ei tehdä. Työssä oletetaan tiedostojen olevan sitä, jota niiden metatiedot kuvaavat. Taulukossa 3 on esitelty tunnuslukujen määrittämisessä ohjelmallisesti käytettävät python-kirjastot. Kyseiset kirjastot on valittu työssä käytettäväksi niiden yleisyyden, mutta myös avoimen lähdekoodin takia, jolloin tutkimuksen tulokset voidaan toistaa ilman kaupallisia ohjelmistoja.

Kirjasto (versio, lyhenne)	Kuvaus	Käyttötarkoitus
Librosa (0.6.2)	Ääni ja musiikkisignaalin analysoimiseen tarkoitettu kirjasto	Äänitiedostojen käsittely, tunnuslukujen laskenta
Matplotlib (2.2.2, plt)	NumPyn tietorakenteisiin perustuva 2D-visualisointikirjasto	Visualisointien tuottaminen, joilla tunnuslukuja kuvataan
NumPy (1.15.2, np)	Tieteelliseen laskentaan tarkoitettu kirjasto, joka tarjoaa kevyitä tietorakenteita ja matemaattisia menetelmiä	Datan tallentaminen, esiprosessointi, matriisien ja vektorien käsittely, matemaattiset laskennat arvojoukoille
SciPy (1.1.0)	Tieteellisen ja teknisen laskennan kirjasto	Signaalinkäsittely, esimerkiksi wav-tiedostojen lukeminen ja aaltomuunnokset

**Taulukko 3.** Laskennassa ja visualisoinnissa käytetyt keskeiset kirjastot

### 6.1 Katkaisijan moottorin virtasignaali

Katkaisijan osalta tunnuslukuja tunnistettiin virittävään moottoriin ja iskunvaimentimeen liittyen. Moottorin osalta anturointia tehtiin virran kulutuksesta ja operoinnista kuuluvasta äänestä. Moottorin virtakäyrästä pystytään tunnistamaan seuraavia tunnuslukuja:


- Viritysaika
- Virrankulutus
- Virtakäyrien vertaaminen dynaamisen aikasovitus etäisyyden avulla

Virtakäyrät luetaan wav-tiedostomuodossa, joka käsittelyä ja analysointia varten on tarpeen muuttaa listamuotoon. Virtatiedostot ovat tässä tilanteessa tunnistettavissa ”\_current.wav” tiedostopäätteestä, jolloin tiedostot voidaan lukea yhteen listamuotoiseen tietorakenteeseen ohjelmassa 1 esitetyllä tavalla. Tietorakenteessa on tallennettuna listaan kaikki ohjaukset. Jokaisesta ohjauksesta on oma listansa, joka pitää sisällään ensin näytteenottotaajuuden ja toisessa indeksissä datapisteet listana.

```
wav_files = []
# dire muuttujaan on talletettu tiedostopolku, jota halutaan lukea
for file in os.listdir(dire):
    filename = os.fsdecode(file)
    # Tarkistetaan, että tiedosto on tyypiltään oikea
    if filename.endswith("_current.wav"):
        wav_files_cb.append(scipy.io.wavfile.read(filename))
```

### ***Ohjelma 1. Virtatiedostojen lukeminen listamuotoon***

Virtatiedostojen lukemisen jälkeen ohjelman 1 avulla, ne voidaan suoraan visualisoida tästä tiedostomuodosta, jotta virtaprofiilia päästään silmämääräisesti tulkitsemaan. Kuvas-  
sassa 9 on esitetty yksittäisen katkaisijan kahtena eri ajankohtana tehtyjen ohjauksien virtaprofiilit.



**Kuva 9.** Katkaisijan kahden eri ohjauksen virtaprofiilit

Katkaisijoiden ohjauksista voidaan laskea viritysaika, ja vertaamalla tätä aikaa saman tyyppisten katkaisijoiden samanlaisissa olosuhteissa tehtyihin mittauksiin, arvioida laitteen kuntoa. Viritysjen määrittäminen tapahtuu laskemalla kulunut aika virtakäyrässä näkyvän ensimmäisen ja viimeisen negatiivisen piikin välillä. Piikkien määrittäminen vaatii signaalin prosessointia, sillä signaali on harvassa kohdassa aidosti kasvavaa tai vähenevää, vaan perättäiset datapisteet vaihtelevat satunnaisesti kohinan takia, vaikka suurempi trendi onkin visuaalisesti erotettavissa. Piikkien tunnistamista varten signaalia tasoitetaan, jolloin pieni vaihtelu perättäisten datapisteiden välillä saadaan jätettyä huomiotta. Tällöin piikkien määrittämisessä saadaan todennäköisemmin tunnistettua todelliset piikit. Signaalin tasoitus tehdään Savitsky-Golay menetelmän avulla. Pressin et al. (1992) mukaan Savitsky-Golayn algoritmissa hyödynnetään pienimmän neliösumman laskentaa, jonka avulla voidaan sovittaa käyrä tarjottuihin datapisteisiin. Tällä tavalla signaalista

saadaan hävitettyä kohinaa, mutta säilytettyä signaalin muoto ja suuruus (Press et al. 1992).

```
# Luodaan tasoitettu signaali
smoothed_signal = scipy.signal.savgol_filter(x=wav_files_cb[0][1],
                                              window_length=51, polyorder=3)


# Virtasignaalin piikit ovat selkeitä, joten piikkien leveytenä voidaan käyttää
# korkeaa arvoa
peak_width = np.arange(1, 3000)

# Signaali annetaan miinusmerkkisenä, sillä tavoitteena on tunnistaa
# negatiiviset piikit
peaks = scipy.signal.find_peaks_cwt(-smoothed_signal, peak_width)

# Erotus jaetaan näytteenottotaajuudella, jotta saadaan aika sekunteina
runtime = (peaks[1]-peaks[0])/wav_files_cb[0][0]
```


### ***Ohjelma 2. Ohjausajan laskeminen virtapiikeistä***

Ohjelmassa 2 luodaan ensin tasoitettu signaali, josta on poistettu kohina, tämän jälkeen annetaan määrittäykset piikkien leveyksistä, havaitaan piikit ja lopulta lasketaan näiden perusteella viritykseen kuluva aika. Kuvassa 10 näkyvälle ohjaukselle saadaan virtapiikkien perusteella laskettua viritysjaksi 8,89 sekuntia.



***Kuva 10. Viritysjajan määrittäminen virtapiikkien avulla***

Moottorin virtaprofiilin integraalin laskemisella ajan yli pystytään numeraalisesti esittämään paljonko moottori käyttää virtaa ohjauksen suorittamiseen eli kuinka paljon varausta siirtyy. Kuvassa 11 on visualisoitu mitä summaintegraalin laskemisella yksittäiselle virtakäyrälle ajan yli tarkoitetaan.



**Kuva 11.** Virrankulutuksen laskeminen summaintegraalilla

Kuvasta 11 nähdään, että integraalin laskemisella tarkoitetaan x-akselin ja virtakäyrän väliin jäävän pinta-alan määrittämistä. Integraalin laskemista varten on määritettävä ajan muutos kahden datapisteen välillä. Tämä onnistuu ottamalla käänteisluku näytteenotto-taajuudesta. Virrankulutuksen laskeminen onnistuu koodin osalta ohjelmassa 3 esitetyllä tavalla.

```
# sf kuvaa näytteenottotaajuutta
def get_dx(sf):
    # ajan muutos kahden datapisteen välillä saadaan käänteisluvulla
    return (1 / sf)

def integrate(y, dx):
    return np.trapz(y=y, dx=dx)

dx = get_dx(wav_files_cb[0][0])
integrate(wav_files_cb[0][1], dx)
```

### **Ohjelma 3.** Virrankulutuksen laskeminen summaintegraalilla

Ohjelmassa 3 esitetyn laskentatavan avulla voidaan varauksen siirtyminen laskea signaalille, josta tiedetään datapisteiden lisäksi näytteenottotaajuus. Kuvassa 11 näkyvälle virtasignaalille saadaan ohjelman 3 avulla määritettyä varauksen siirtymiseksi -18,59 coulombia. Kuvassa 9 näkyvälle saman katkaisijan toisen ohjauksen oranssina kuvatulle virtasignaalilla saadaan määritettyä integroimalla arvo -18,63 coulombia. Saman katkaisijan kahdelle eri ohjaukselle virrankulutukset eroavat vain hyvin vähän. Tämä kertoo, ettei varauksen siirtymisen näkökulmasta laitteen toiminta ole juurikaan muuttunut.

Edellä laskettujen tunnuslukujen lisäksi moottorin virtakäyriä voidaan verrata toisiinsa dynaaminen aikasovitus -algoritmin avulla, jolloin on mahdollista tunnistaa, minkä verran moottorin virtakäyrä poikkeaa vertailukohteesta. Vertailukohteena voi toimia esimerkiksi saman laitteen edeltävän ohjauksen virtaprofiili tai vaihtoehtoisesti hyväkuntoiseksi todetun laitteen tietyn elinkaaren vaiheen aikainen virtaprofiili.

Dynaamisen aikasovitus etäisyyden laskeva funktio vertailee kahta funktion parametreina saatavaa listamuodossa olevaa virtakäyrrää toisiinsa. Paluuarvona funktio palauttaa listojen välille lasketun dynaamisen aikasovitus etäisyyden. Korkea etäisyys tarkoittaa käyrien välillä olevan suuria eroavaisuuksia. Dynaaminen aikasovitus etäisyys voidaan laskea seuraavasti:

```
def DTW_distance(current1, current2):
    dtw = {}
    # Annetaan alustavat arvot
    for nbr in range(len(current1)):
        dtw[(nbr, -1)] = float(math.inf)
    for nbr in range(len(current2)):
        dtw[(-1, nbr)] = float(math.inf)
    dtw[(-1, -1)] = 0
    # Haetaan paras sovituspolk
    for x in range(len(current1)):
        for y in range(len(current2)):
            seperation = (current1[x]-current1[y])**2
            dtw[(x,y)] = seperation + min(dtw[(x-1,y)], dtw[(x,y-1)],
                                           dtw[(x-1,y-1)])
    return ((dtw[(len(current1)-1, len(current2)-1)] ** (1/2))

# Funktion kutsuminen listaan luetuilla virtatiedostoilla
dtw_value = DTW_distance(wav_files[0][1], wav_files[1][1])
```

#### ***Ohjelma 4. Dynaamisen aikasovitus etäisyyden laskeminen kahdelle listalle***

Dynaamisen aikasovituksen laskeminen on hyvin raskasta, sillä esimerkkitapauksessa kuvassa 9 esitettyjen kahden katkaisijan ohjauksen (noin 10 000 datapistettä per ohjaus) vertailulaskenta kesti tehokkaallakin tietokoneella useamman minuutin ajan. Kuvassa 9 näkyvien ohjausten DTW-etäisyydeksi saadaan ohjelmassa 4 esitetyn funktion avulla määritettyä arvo 241,48.

## 6.2 Katkaisijan moottorin äänisignaali

Moottorin toinen anturointitapa Kymin asemalla on ohjauksista kuuluvien äänien nauhoittaminen mikrofoniin avulla, jolloin audiosignaalista voidaan laskea moottorin äänispektri. Käsittelemätön ääni luetaan wav-tiedostona, joka sisältää ääneen liittyviä tietoja eli näytteenottotaajuuden ja äänisignaalin. Äänitiedoston lukeminen tapahtuu vastaavalla tavalla kuin virtatiedoston lukeminen, joka on esitetty ohjelmassa 1. Lukemisen jälkeen voidaan visualisoida äänitiedoston raakasignaali, joka kuvaa painetta ajan funktiona. Katkaisijan ohjauksen moottorista nauhoitettu raakasignaali on nähtävillä kuvassa 12.



**Kuva 12.** Katkaisijan moottorin raakasignaali


Äänitiedoston raakasignaalista halutaan laskea spektri yksittäiselle aikaikkunalle sekä spektrogrammi kuvaamaan spektrin muutosta ajan ylitse, jolloin luvussa 5.1 tunnistettujen spektrin tunnuslukujen laskeminen ja äänisignaalin visualisoiminen ovat mahdollisia. Tässä työssä ei oteta kantaa optimaalisen ikkunan määrän valitsemiseen, vaan esimerkeissä käytetään audiosignaalin jakamista tuhanteen ikkunaan, jossa peräkkäisillä ikkunoilla on 50 % yhteisiä datapisteitä. Spektrin laskeminen ikkunalle onnistuu FFT-muunnoksella, jonka käyttö ja visualisoiminen ovat suoraviivaisia pythonin SciPy-kirjaston avulla:

```
def windowing(data, window_amount):
    windowed_signals = []
    win_step = int(len(data) / window_amount)
    # Alustetaan ikkunan alun ja lopun määräävät indeksit
    win_start = 0
    win_end = window_size
    while win_start <= len(data):
        windowed_signals.append(data[win_start:win_end])
        # Muutetaan parametreja seuraavaan ikkunaan pyöristäen ylöspäin
        win_start += math.ceil(window_size / 2)
        win_end += math.ceil(window_size / 2)
    return windowed_signals

windowed_signals = windowing(wav_files_cb[0][2], 1000)
```

```
# Tehdään valitulle ikkunalle FFT-muunnos
fft_result = np.fft.fft(windowed_signals[100])
```

### **Ohjelma 5.** Signaalin ikkunointi ja FFT-muunnos ikkunalle



**Kuva 13.** Katkaisijan moottorin taajuusspektri kahdelle perättäiselle ikkunalle


Yksittäiset spektrit lasketaan aina valitulle aikaikkunalle. Niissä ei siis ole nähtävissä ajallista muutosta, jolloin mahdollisuudeksi jää perättäisten ikkunoiden taajuusspektrien vertaaminen. Tämä on kuitenkin haastavaa, sillä ikkunoita voi olla runsaasti. Ongelman ratkaisuksi voidaan muodostaa spektrogrammi, joka kuvaa spektrin muutosta ajan suhteen. Spektrogrammissa värillä kuvataan äänen intensiteettiä, y-akselilla taajuutta ja x-akselilla keskiarvoistettua aikaa, sillä absoluuttisen ajan kertominen ei ole mahdollista ikkunoinnin takia. Spektrogrammi voidaan laskea ja visualisoida seuraavasti

```
# Audiosignaalin data
data = np.array(wav_files_cb[0][1])
# Audion näytteenottotaajuus
sf = wav_files_cb[0][0]

frequencies, times, spectrogram = scipy.signal.spectrogram(data, fs=sf,
                                                             nperseg=10000, noverlap=9000)
plt.pcolormesh(times, frequencies, np.log(spectrogram))
plt.xlim(0,10)
plt.ylim(0,1000)
plt.show()
```

### **Ohjelma 6.** Spektrogrammin laskeminen ja visualisointi

Ohjelmassa 6 esitetty spektrogramin laskeminen suorittaa annetulle ikkunaleveydelle FFT-muunnoksen ja palauttaa lasketut taajuudet, aikayksiköt ja spektrogrammin. Spektrogrammin parametreiksi annetaan käytettävä ikkunointipituus sekä vierekkäisille ikkunoille päällekkäiset datapisteet. Päällekkäisille datapisteille annetaan lähes ikkunointipituutta vastaava arvo, jonka avulla spektrogrammista pystytään helposti tulkitsemaan muutosta ajan yli. Spektrogrammin visualisoinnissa käytetään äänen intensiteetille eli kuvassa näkyvälle värille logaritmista asteikkoa, jolloin suhteelliset muutokset korostuvat voimakkaammin. Visualisoinnissa rajataan tarkastelu ajallisesti ensimmäiseen 10 sekuntiin, jonka aikana ohjaus ehtii tapahtua ja taajuuden osalta 10000 Hz:n, sillä tämän puolella olevat ylätaajuudet sisältävät vain vähän informaatiota. Katkaisijan ohjauksen aikainen moottorin spektrogrammi on visualisoitu kuvassa 14.



**Kuva 14.** Katkaisijan moottorin spektrogrammi

Tässä työssä ei oteta kantaa, mille osalle äänitiedostoa tunnuslukuja tulisi laskea, tai minkä tyylistä ja kokoista ikkunointia vikatilän parhaaseen mahdolliseen tunnistamiseen tulisi käyttää. Tässä luvussa esitellään, miten spektrin tunnusluvut lasketaan 10000 datapistettä sisältäville ikkunoille. Yksittäisen tunnusluvun arvojoukkojen kuvaamiseen käytetään histogrammia ja esitetään tunnusluvun muutos alkuperäiseen raakasignaaliin nähden. Histogrammin avulla tarjotaan käsitys arvojen vaihteluvälistä ja jakaumasta. Äänen spektreihin liittyen tunnistettiin luvussa 5.1 seuraavia tunnuslukuja:

- spektrin keskipiste
- spektrin vinous
- nollanylitystaajuus
- MFCC



Spektrin tunnuslukujen laskenta onnistuu yksinkertaisesti pythonin librosa-kirjaston avulla. Ohjelmakoodin osalta tunnistetut tunnusluvut palauttavat funktiot ovat nähtävillä ohjelmassa 7.

```
# audio-muuttuja sisältää rajatun äänisignaalin listamuodossa
# Spektrin vinous
def get_rolloff(audio, sf, winsize):
    return librosa.feature.spectral_rolloff(y=audio, sr=sf, n_fft=winsize)[0]

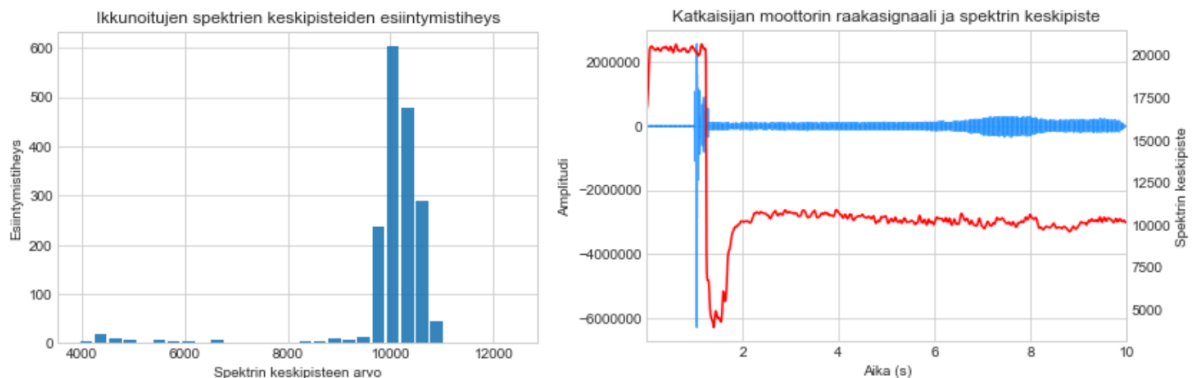
# Spektrin keskipiste
def get_centroid(audio, sf, winsize):
    return librosa.feature.spectral_centroid(y=audio, sr=sf, n_fft=winsize)[0]

# Nollanylitystaajuus
def get_zero_crossing(audio, winsize):
    return librosa.feature.zero_crossing_rate(y=audio, frame_length=winsize,
                                              hop_length=(math.floor(window_size/2)))[0]

# MFCC-arvot
def get_mfcc(audio, sf):
    return librosa.feature.mfcc(y=audio, sr=sf)
```


### *Ohjelma 7. Spektrin tunnuslukujen laskeminen*

Ohjelmasta 7 nähdään, että tunnuslukujen laskemiseen vaadittavia tietoja ovat itse signaalin lisäksi näytteenottotaajuus ja haluttu ikkunan leveys. Kuvassa 12 näkyvälle ohjaukselle laskettu spektrin keskipiste saa arvoja väliltä [3943, 20665]. Arvojen esiintymistiheys ja tunnusluvun muuttuminen suhteessa raakasignaaliin ajan yli on esitetty kuvassa 15.




**Kuva 15.** *Spektrin keskipiste katkaisijan moottorin äänisignaaliin*

Kuvassa 15 näkyvän ikkunoitujen spektrien keskipisteiden esiintymistiheyden histogrammista on jätetty pois lukuarvon 12500 ylittävät arvot. Nämä arvot ovat peräisin audiosignaalin alusta, jolloin ohjaus ei ole vielä alkanut. Kyseiset arvot siis kuvaavat pelkkää kohinaa, eivätkä tämän takia ole mielekkäitä tarkastelun kannalta. Alun kohinan jälkeen spektrin keskipiste laskee hetkellisesti välille [4000; 6000], jolloin äänessä kuuluu voimakasäänistä iskunvaimentimen toimintaa. Tämän jälkeen äänisignaaliin kuuluu tasaisesti moottorin toiminnan ääntä, jolloin spektrin keskipiste liikkuu välillä [8000; 11000]. Vastaavantyyppinen histogrammi ja raakasignaalin sekä tunnusluvun muuttuminen ajan yli on kuvattuna spektrin vinoudelle kuvassa 16.



**Kuva 16.** *Spektrin vinous katkaisijan moottorin äänisignaali*

Kuvassa 16 näkyvälle histogrammille tehtiin vastaava suodatus kuin spektrin keskipisteelle, sillä alun kohinasta syntyvät yli 22500 suuruiset lukuarvot jätetään tarkastelun ulkopuolelle. Vurityksen alkaessa spektrin vinoudet saavat hetkellisesti arvoja välillä [6000; 9000]. Iskunvaimentimen äänien päätyttyä moottorin toiminnan spektrien vinoudet saavat lukuarvoja välillä [12000; 20000]. Spektrin vinouden muutoksesta ajan yli piirretty käyrä muistuttaa pääsääntöisesti spektrin keskipisteen käyrää, mutta ohjauksen loppupuolella on huomattavissa jonkin verran eroavaisuutta. Vastaavat kuvaajat äänisignaalin nollanylitystaajuudelle on esitetty kuvassa 17.

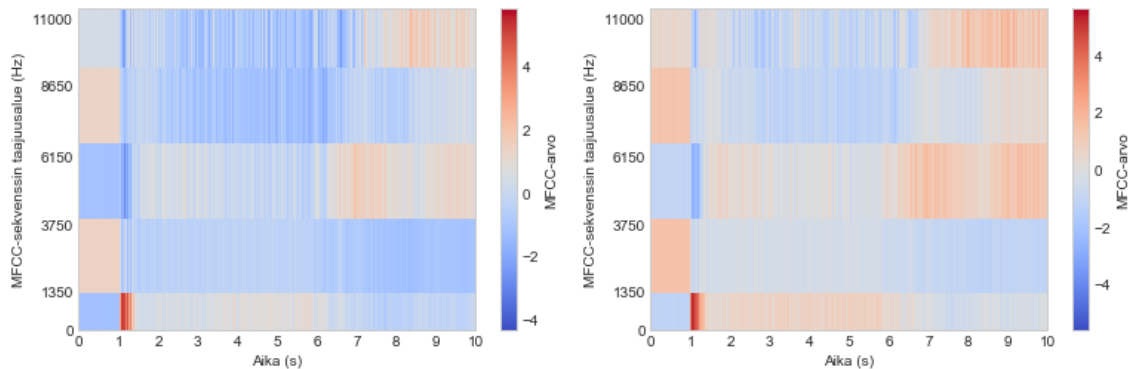


**Kuva 17.** *Spektrin nollanylitystaajuus katkaisijan moottorin äänisignaali*

Kuvan 17 histogrammille tehtiin suodatus, jonka perusteella jätettiin signaalin alussa esiintyvät kohinasta johtuvat alle 0,03 suuruiset nollanylitystaajuudet pois. Nollanylitystaajuuden käyrä eroaa merkittävästi spektrin keskipisteen ja vinouden muodosta. Iskunvaimentimen äänten jälkeen nollanylitystaajuus nousee matalammista arvoista arvovälille [0,15; 0,19], jossa se liikkuu lähes koko moottorin toiminnan ajan, kunnes signaalin lopussa alkaa laskea alhaisempiin arvoihin.


MFCC-arvoista jätetään ensimmäisen suodattimen tuottama arvojoukko pois sen heikon erottelukyvyn takia. Tämän jälkeen huomioidaan viisi seuraavaa suodatinta, jolloin käsiteltävänä ovat alle 11000 Hz olevat taajuudet. Tämän taajuusarvon yläpuolella olevat arvot kuvaavat lähinnä signaalien kerrannaisia sekä kohinaa, ja omaavat vain vähän infor-

maatioarvoa, joten ne voidaan jättää tarkastelun ulkopuolelle. Kuvassa 18 on esitetty saman katkaisijan kahden eri ohjauksen skaalattujen MFCC-arvojen vaihtelu spektrogrammina katkaisutapahtuman aikana.



**Kuva 18.** Katkaisijan moottorin kahden ohjauksen MFCC-arvoja

MFCC-tunnusluvut saavat toisella suodattimella korkeimmat arvot, jolloin arvot vaihtelevat välillä [5; 211]. Muut suodattimet saavat lukuarvoja välillä [-98; 70]. Kuvassa 18 näkyvää visualisointia varten MFCC-arvot skaalattiin välille [-5; 5], jotta suodattimien väliset erot ovat selkeämmin havaittavissa. Kuvassa 18 näkyvän vasemmanpuoleisen ohjauksen alle 11000 Hz skaalaamattomien MFCC-arvojen esiintymistiheydet on visualisoitu kuvassa 19.



**Kuva 19.** Yksittäisen katkaisijan ohjauksen MFCC-arvojen esiintymistiheydet

### 6.3 Katkaisijan iskunvaimentimen äänisignaali

Katkaisijan toinen mitattava mekaaninen komponentti on iskunvaimennin. Iskunvaimentimeen liittyen tunnistettiin seuraavia värähtelysignaalin tunnuslukuja:

- Tehollisarvo
- Huipusta huippuun -arvo
- Huippukkuus
- Huippukerroin

Tunnusluvut lasketaan ohjausyksikön sisältä iskunvaimentimen läheltä nauhoitetusta wav-tyyppisestä äänitiedostosta. Äänitiedostossa kuuluu myös muut kuin pelkästään iskunvaimentimen toimintaan liittyvät äänet. Tämän takia tarkasteltua äänisignaalia on syytä rajoittaa iskunvaimentimen toimintaan. Tarkasteltaessa kuvassa 12 näkyvää raaka-signaalia voidaan iskunvaimentimen toimintaan liittyvät äänet sijoittaa ajallisesti noin 1 sekunnin kohdalle. Kyseinen ääni on melko lyhytkestoinen, joka alkaa hiljaisuudesta ja hälvenee nopeasti moottorin käyntiäänien alle. Tunnuslukujen laskentaa varten tehtävässä signaalin leikkaamisessa tunnistetaan iskunvaimentimen toiminnan alkuaika, jonka perusteella leikataan ikkunan alkuajaksi 0,1 sekuntia ennen tämän alkua ja tästä eteenpäin 0,6 sekuntia. Iskunvaimentimien toiminta kestää visuaalisesti tulkiten käytetyssä esimerkkisignaalissa noin 0,4 sekuntia, joten koko tapahtuma saadaan valitulla ikkunalla talteen. Iskunvaimentimen toiminnan päättymistä on huomattavasti hankalampi määrittää, sillä tällöin moottorin toiminnasta syntyvät äänet sotkevat signaalia. Tämän takia ikkunassa käytetään kiinteää ikkunan pituutta. Iskunvaimentimen tunnuslukujen laskentaa hyödynnettävät koodit on esitetty ohjelmassa 8.

```
# Huipusta huippuun -arvo
def get_peak_to_peak(signal):
    return (max(signal) - min(signal))

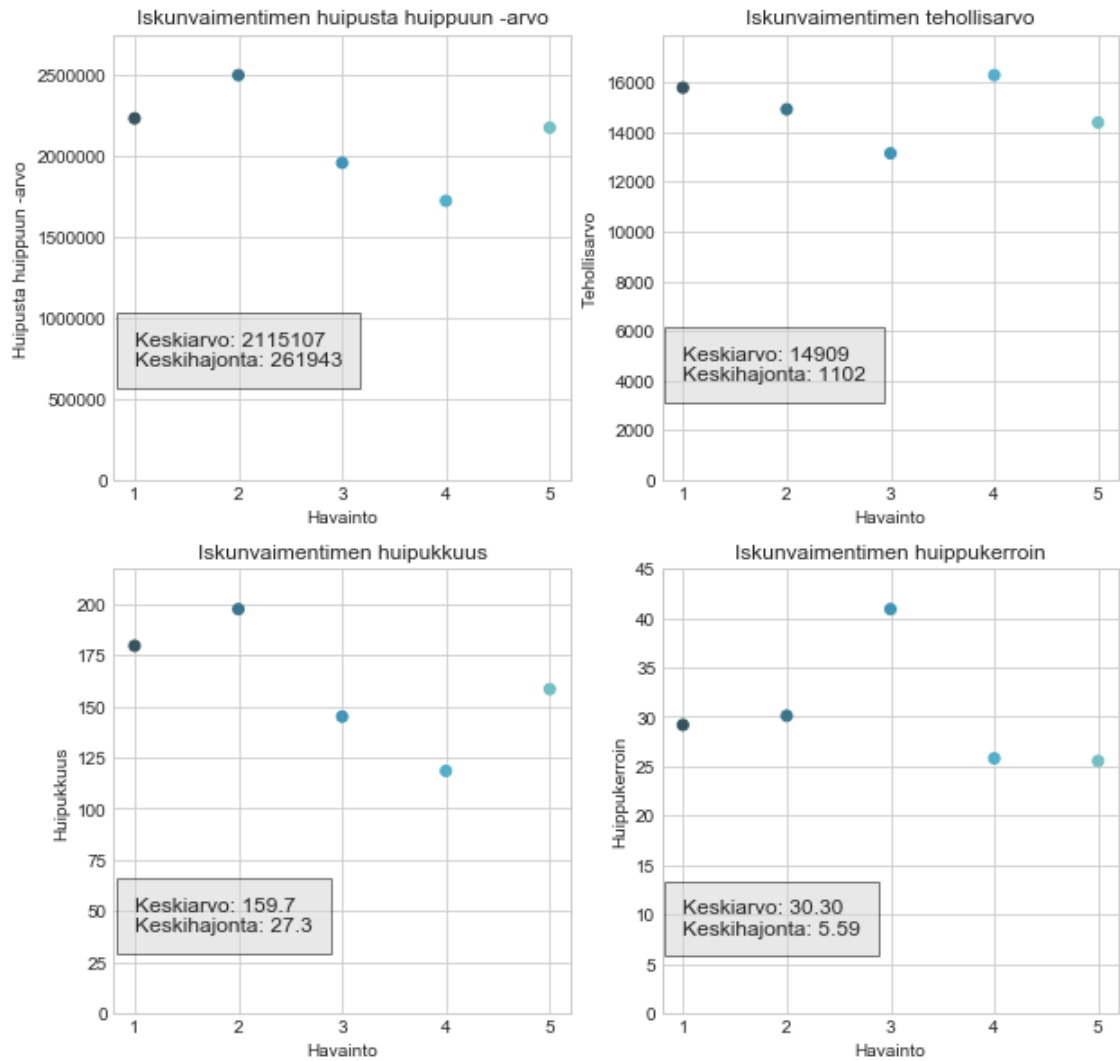
# Tehollisarvo
def get_root_mean_square(signal):
    return np.sqrt(np.mean(np.array(signal)**2))

# Huipukkuus
def get_kurtosis(signal):
    return scipy.stats.kurtosis(signal)

# Huippukerroin
def get_crest_factor(signal):
    peak_value = max(signal)
    rms = get_root_mean_square(signal)
    return np.divide(peak_value, rms)
```

### ***Ohjelma 8. Iskunvaimentimen ja vaihteiston tunnuslukujen laskeminen***

Ohjelmassa 8 esitetyille funktioille annetaan parametrina iskunvaimentimen toimintaan rajattu äänisignaali. Tutkimusta varten tunnusluvut laskettiin viidelle saman katkaisijan ohjaukselle. Huipusta huippuun –arvojen osalta tunnuslukujen vaihteluväliksi saatiin kolmen merkitsevän numeron tarkkuudella [1720000; 2500000], tehollisarvon vaihteluväliksi [13100; 16300], huipukkuuden vaihteluväliksi [118; 197] ja huippukertoimen vaihteluväliksi [25,5; 40,9]. Katkaisijan iskunvaimentimen viiden ohjauksen lasketut tunnusluvut, tunnuslukujen keskiarvot sekä keskihajonnat on esitetty kuvassa 20.



**Kuva 20.** Iskunvaimentimen tunnusluvut esimerkkidatalle


Kuvassa 20 näkyvien tunnuslukujen keskiarvojen ja keskihajontojen perusteella voidaan kullekin tunnusluvulle laskea variaatiokerroin. Variaatiokertoimen avulla voidaan vertailla eri mittaskaalassa olevien havaintojen hajontoja, ja se saadaan laskettua keskihajonnan ja keskiarvon osamääränä. Huipusta huippuun -arvolle saadaan variaatiokertoimeksi 12,4, tehollisarvolla 7,4, huippukkuudelle 17,1 ja huippukertoimelle 18,4. Variaatiokertoimen perusteella pienin hajonta on tehollisarvolla ja suurin huippukertoimella. Tarkasteltaessa huippukertoimen havaintopisteitä huomataan kuitenkin nopeasti, että neljä viidestä havainnosta ovat hyvin säännöllisiä, mutta yksi poikkeaa merkittävästi. Suurempia johtopäätöksiä tunnuslukujen hajonnasta ei kuitenkaan ole syytä tehdä, sillä otoskoko on hyvin minimaalinen.

## 6.4 Erottimen ja maadoituskytkimen moottorin virtasignaali

Erottimen ja maadoituskytkimen osalta tunnuslukuja tunnistettiin ohjausten liike-energian tuottaviin moottoreihin ja vaihteistoon liittyen. Erottimissa ja maadoituskytkimissä


mittausasetelma on samanlainen ja tunnusluvut lasketaan samanlaisista mittauksista. Teknisesti tämä tarkoittaa, että samaa ohjelmakoodia voidaan käyttää molempien tunnuslukujen erottamiseen. Aiemmassa vaiheessa tässä luvussa tunnistettuja katkaisijan tunnuslukujen laskentaan hyödynnettäviä ohjelmia pystytään yhtä lailla hyödyntämään myös erottimille ja maadoituskytkimille. Laitteista esitetään kuitenkin omat visualisoinnit, sillä tunnusluvut eri laitetyypeillä eivät ole keskenään vertailukelpoisia.

Erottimen sekä maadoituskytkimen moottorista on tunnistettavissa samat tunnusluvut kuin myös katkaisijan moottorista, vaikka moottorien funktio onkin laitteissa hyvin erilainen. Kuvassa 21 on esitetty saman erottimen kaksi aukiohjausta ja kaksi kiinniohjausta eri mittausajankohdista.



**Kuva 21.** Erottimen ohjauksien virtaprofiileja

Kuvasta 21 nähdään, että tarkastellun erottimen auki- ja kiinniohjausten virtaprofiilit muistuttavat silmämääräisesti hyvin toisiaan. Kuvassa 21 näkyvien ohjauksien dynaamisen aikasovituksen etäisyydeksi saadaan ohjelman 4 avulla laskettua aukiohjaukselle 126,3 ja kiinniohjaukselle 132,9. Kuvassa 22 puolestaan esitetään yksittäisen maadoituskytkimen kahden aukiohjauksen ja kahden kiinniohjauksen virtaprofiilit.




**Kuva 22.** Maadoituskytkimen ohjauksien virtaprofiileja

Kuvassa 22 näkyvistä maadoituskytkimien ohjauksista tehdään hyvin samanlaiset huomiot kuin edellä esitellyistä erottimien virtaprofiileista. Visuaalisesti merkittäviä eroja ei ole huomattavissa, vaan aukiohjaukset muistuttavat toisiaan kuten myös kiinniohjaukset.

Kuvassa 22 näkyville aukiohjauksille saadaan laskettua dynaamisen aikasovituksen etäisyydeksi lukuarvo 138,9 ja kiinniohjaukselle puolestaan arvo 88,7. Aukiohjauksien tunnistaminen merkittävästi erilaisiksi kiinniohjauksiin verrattuna ei visuaalisesti tulkiten onnistu.

Virtakäyristä voidaan vastaavalla tavalla kuin katkaisijalle myös erottimelle ja maadoituskytkimelle laskea ohjauksen kesto eli ohjausaika sekä ohjauksen aikana tapahtuva virrankulutus. Tunnuslukujen määrittämisen näkyminen virtakäyrissä on visualisoitu yksittäiselle erottimen auki- ja yksittäiselle maadoituskytkimen kiinniohjaukselle kuvassa 23.




**Kuva 23.** Erottimen ja maadoituskytkimen ohjauksien ohjaus-ajat ja virrankulutus

Laskenta tapahtuu virrankulutukselle täysin vastaavalla tavalla kuin katkaisijalle eli ohjelman 3 avulla. Ohjausajan suhteen idea toimii samalla tavalla kuin katkaisijalle on esitetty ohjelmassa 2, mutta saman suuntaisten piikkien tunnistamisen sijaan on tunnistettava ohjauksille yksi positiivinen ja yksi negatiivinen piikki. Aukiohjauksille positiivinen piikki tulee ensin ja kiinniohjauksille puolestaan negatiivinen piikki. Kuvassa 23 näkyvälle erottimen virtakäyrälle saadaan ohjelmien 2 ja 3 avulla laskettua ohjaus-ajaksi 6,73 sekuntia ja virrankulutukseksi eli varauksen siirtymiseksi 684,7 coulombia. Kuvan 23 maadoituskytkimen kiinniohjaukselle puolestaan saadaan ohjaus-ajaksi 5,67 sekuntia ja virrankulutukseksi -377,9 coulombia.

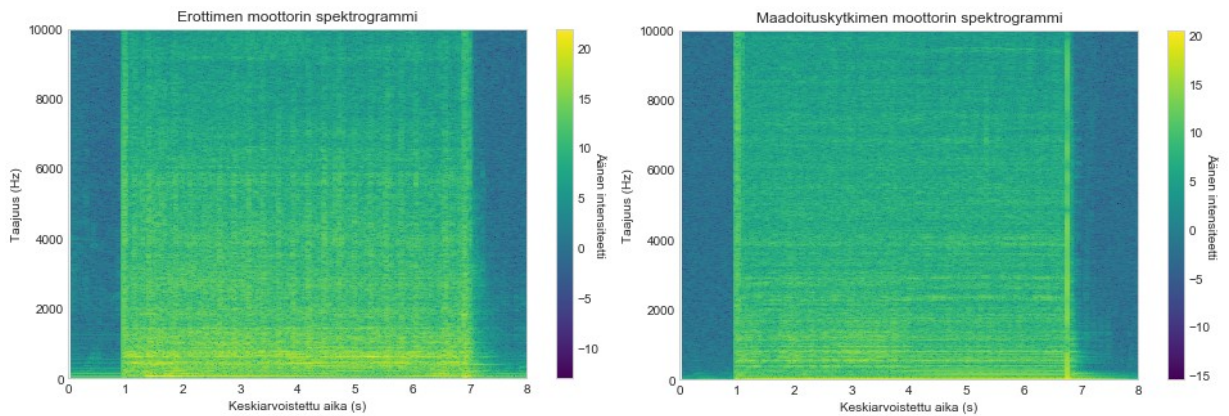
## 6.5 Erottimen ja maadoituskytkimen moottorin äänisignaali

Virtamittauksen lisäksi erottimien ja maadoituskytkimien moottorien kuntoa voidaan arvioida, kuten katkaisijoitakin, moottorin toiminnasta kerättävän äänen perusteella. Kuvassa 24 on nähtävillä erottimen ja maadoituskytkimen moottorien äänitiedostojen raakasignaalit.



**Kuva 24.** Erottimen ja maadoituskytkimen moottorien raakasignaalit

Erottimen ja maadoituskytkimen spektrogrammin laskeminen onnistuu vastaavalla tavalla kuin katkaisijalle ohjelmassa 6 esitetyllä koodilla. Ainut koodiin vaadittava muutos on katkaisijan moottorin äänen raakasignaalin sijaan käyttää erottimen tai maadoituskytkimen moottorin äänen raakasignaalia. Erottimen ja maadoituskytkimen moottorien toiminnan spektrogrammit on visualisoitu kuvassa 25.

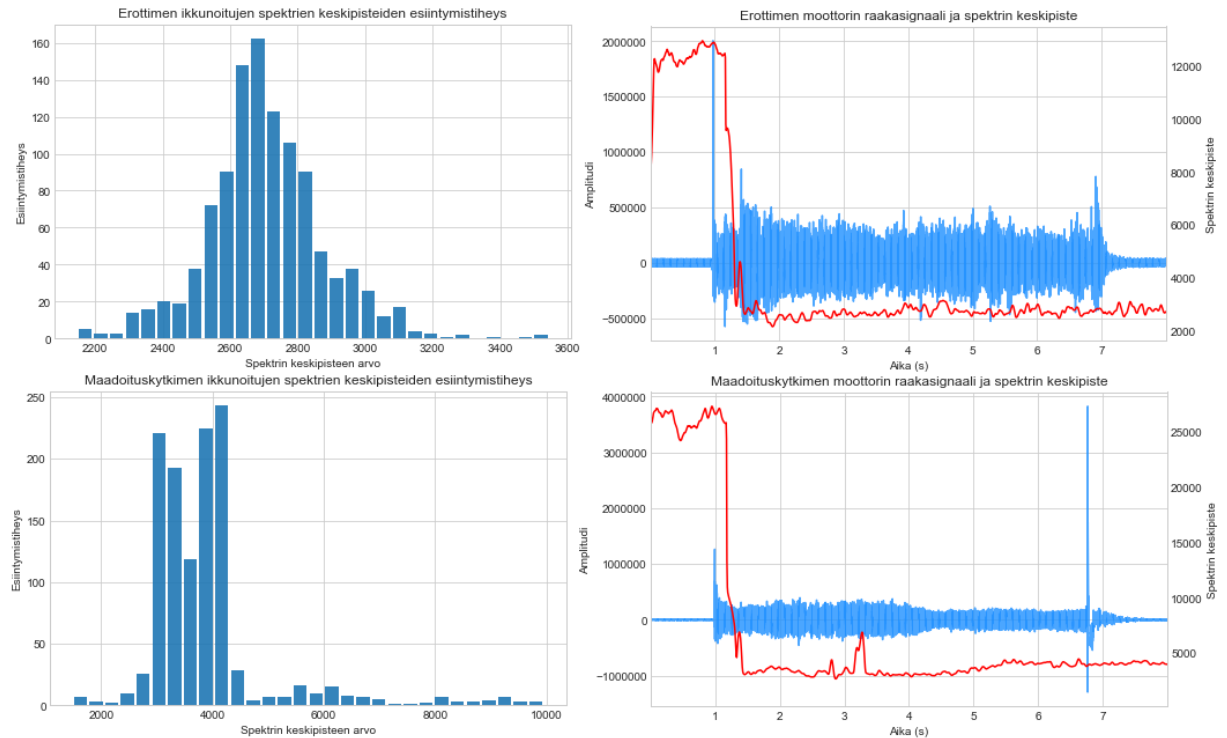


**Kuva 25.** Erottimen ja maadoituskytkimen moottorien spektrogrammit

Kuvassa 25 näkyvistä spektrogrammeista voidaan huomata, että erottimilla ja maadoituskytkimillä spektrit ovat asettuneet huomattavasti tasaisemmin kuin katkaisijoille koko tarkasteltavalle taajuusalueelle mittausaikana. Spektrogrammeista ei ole siis huomattavissa yhtä selkeitä korkeita äänen intensiteettejä tietyillä taajuustasoilla. Tämä voi tarkoittaa haasteita informaation erottamisessa, sillä kohinan erottaminen varsinaisesta signaalista vaatii enemmän esiprosessointia. Toisaalta spektrogrammin muodon kuuluu myös olla huomattavasti tasaisempi, sillä ohjausajana ei erottimissa tai maadoituskytkimissä kuulu yhtä paljon muista lähteistä peräisin olevia ääniä kuin katkaisijoille.



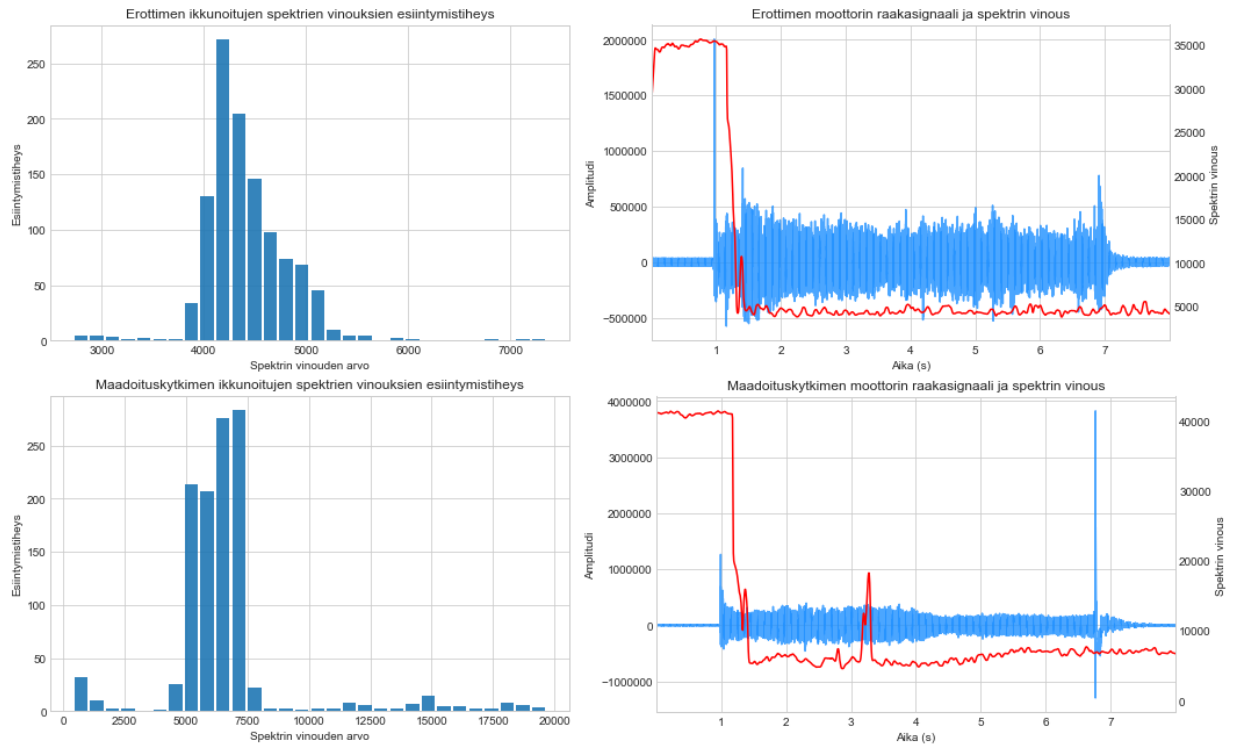
Spektriin liittyvät tunnusluvut saadaan laskettua vastaavalla tavalla kuin katkaisijalle ohjelmassa 7 esitettyjen funktioiden avulla. Kuvassa 26 on nähtävillä erottimen ja maadoituskytkimen moottorien äänisignaalista lasketut ikkunoitujen spektrien keskipisteet.



**Kuva 26.** Erottimen ja maadoituskytkimen moottorien spektrin keskipisteet

Verrattaessa kuvassa 26 näkyvää erottimen moottorin raakasignaalia ja spektrin keskipistettä, voidaan huomata alun kohinan jälkeen spektrin keskipisteen saavan arvoja välillä [2100; 3500]. Signaalin ensimmäisen sekunnin aikana ei ääntä ole erotettavissa ja näkyvä signaali on pelkkää kohinaa. Tämän takia myöskään spektrin keskipisteen arvot eivät sisällä tältä osin informaatiota, vaan ne voidaan jättää huomiotta. Erottimen ikkunoitujen spektrien keskipisteiden esiintymistiheydessä on jätetty lukuarvon 3600 ylittävät arvot pois tarkastelusta. Tällöin keskipisteen esiintymistiheyden jakauma muistuttaa normaali-jakaumaa.

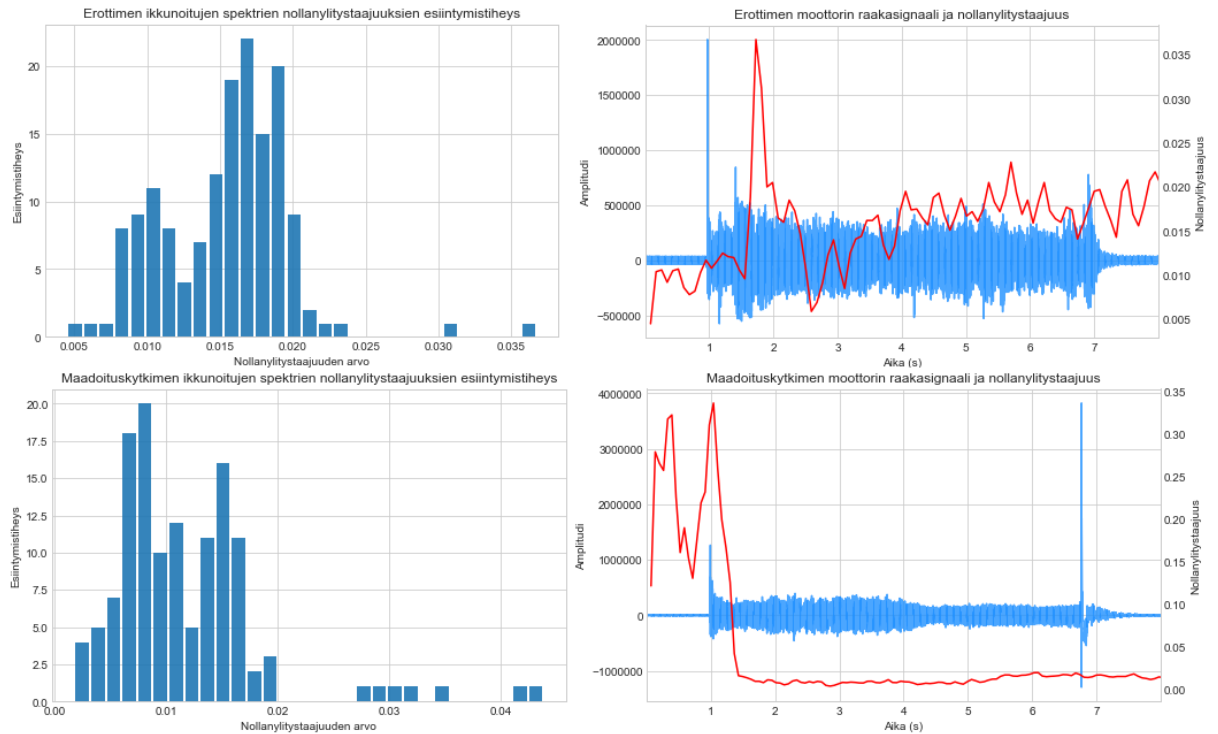
Maadoituskytkimen moottorin kohdalla spektrin keskipisteet saavat alun kohinan jälkeen arvoja pääsääntöisesti välillä [2300; 4500]. Muutoin melko säännöllisessä signaalissa moottorin toiminnan aikana on kuitenkin huomattavissa selkeä piikki hieman kolmen sekunnin jälkeen. Tämä näkyy maadoituskytkimen spektrien keskipisteiden esiintymistiheyden histogrammissa siten, että ilmenneitä arvoja on lähes arvoon 10000 saakka. Histogrammista on jätetty pois lukuarvon 10000 ylittävät arvot, sillä nämä johtuvat alun kohinasta, eivätkä ole mielekkäitä tarkastelun kannalta. Keskipisteiden esiintymistiheyksien jakauma ei muistuta samalla tavalla normaalijakaumaa kuin erottimen kohdalla.



**Kuva 27.** Eroittimen ja maadoituskytkimen moottorien spektrin vinoudet

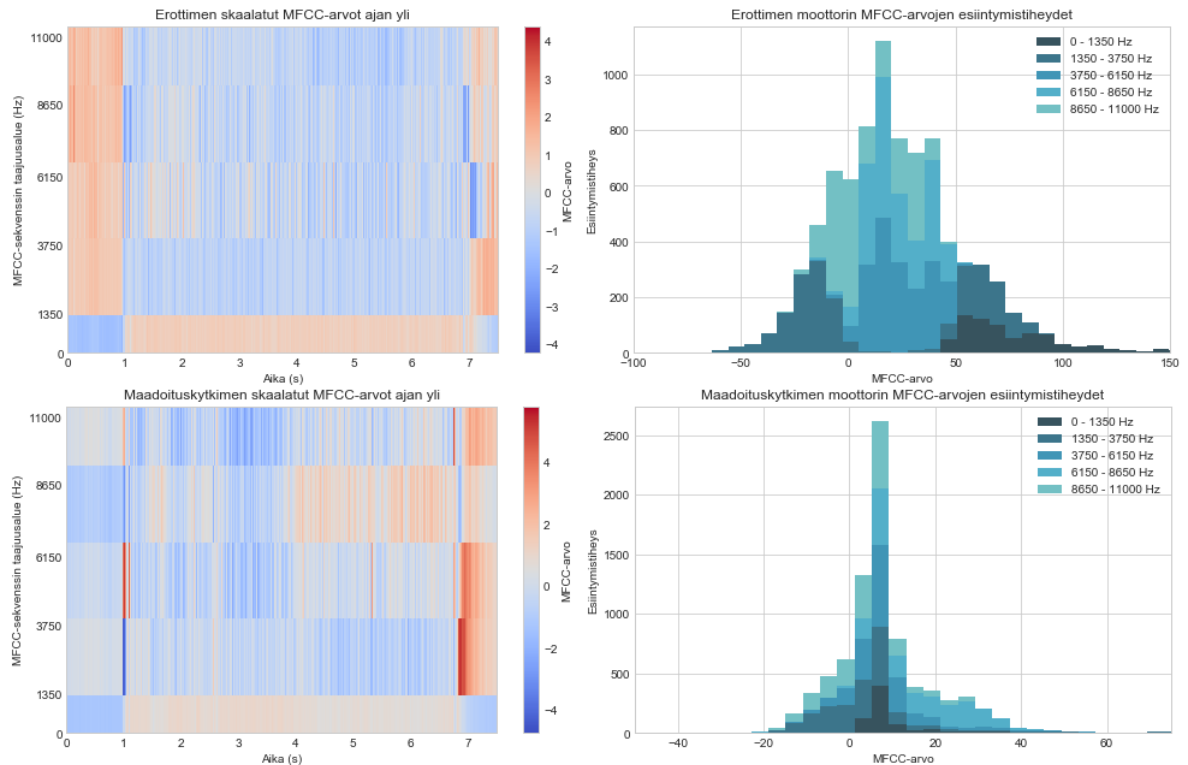
Kuvassa 27 on nähtävillä erottimen ja maadoituskytkimen moottorien ikkunoitujen spektrien vinoudet. Eroittimen osalta spektrin vinous laskee alun kohinan jälkeen arvovälille [2800; 7000], jossa signaali etenee arvoalueella tasaisesti ilman merkittäviä piikkejä tai trendejä. Histogrammin osalta tarkastelusta on jätetty lukuarvon 7500 ylittävät spektrin vinouden arvot, jotka ovat peräisin alun hiljaisesta äänestä. Tällöin signaalin spektrin vinoudet sijoittuvat pääsääntöisesti välille [3500; 5500], jossa jakauma on vasemmalle vino. Verrattaessa raakasignaalia ja spektrin vinouden kehitystä ajan yli, muistuttaa erottimen moottorin spektrin vinous hyvin läheisesti kuvassa 26 näkyvän spektrin keskipisteen muutosta.

Maadoituskytkimen moottorin spektrin vinouden kehitys eroaa muodoltaan selkeästi erottimen moottorin spektrin vinoudesta. Alun hiljaisuuden jälkeen spektrin vinous laskee kulkemaan lievästi kasvavalla trendillä arvovälille [4000; 8000]. Tämän lisäksi maadoituskytkimen moottorin spektrin vinoudessa on huomattavissa selkeä piikki kolmen sekunnin jälkeen, jolloin spektrin vinous kasvaa hetkellisesti lähes lukuarvoon 18000. Piikki on ajallisesti samalla hetkellä kuin kuvassa 26 näkyvä maadoituskytkimen spektrin keskipisteen piikki. Maadoituskytkimen spektrin vinouksien esiintymistiheyden histogrammissa rajoitettiin hiljaisuudesta johtuvat arvot 20000 ylittävät spektrin vinoudet. Tämän jälkeen histogrammin piikit ovat pääsääntöisesti välillä [4500; 7700], jonka lisäksi spektrin vinouksia löytyy aina lukuarvoon 20000 saakka. Tätä korkeammat arvot ovat peräisin alun hiljaisuudesta ja jätetty tarkastelun ulkopuolelle.



**Kuva 28.** *Erottimen ja maadoituskytkimen moottorien spektrin nollanylitystaajuudet*

Kuvassa 28 on esitetty erottimen ja maadoituskytkimen moottorin äänisignaalin spektrin nollanylitystaajuuden muutos ajan yli verrattuna raakasignaaliin ja nollanylitystaajuuden esiintymistiheys. Erottimen osalta nollanylitystaajuuden muoto näyttää hyvin poikkeavalta muihin tunnuslukuihin nähden, sillä alun hiljaisuus ei ole tuottanut korkeita nollanylitystaajuuksia. Verrattaessa erottimen ja moottorin nollanylitystaajuuksia on siis huomioitava, että raakasignaalin kanssa erottimen asteikko on välillä  $[0; 0,035]$  ja maadoituskytkimellä puolestaan  $[0; 0,35]$ . Laitetyyppien nollanylitystaajuuksien samankaltaisuus on havaittavissa histogrammeissa, jossa maadoituskytkimeltä on suodatettu pois lukuarvon 0,5 ylittävät arvot. Todellisuudessa tunnusluvun käyttäytyminen ajan yli on alun hiljaisuuden jälkeen hyvinkin samankaltaista molemmilla laitteilla. Myöskään esiintymistiheyksien histogrammeissa ei ole havaittavissa merkittäviä eroavaisuuksia muuta kuin skaalan suhteen.



**Kuva 29.** Erottimen ja maadoituskytkimen MFCC-arvoja


Kuvassa 29 on esitetty erottimen ja maadoituskytkimien moottorien äänisignaalista laskettujen MFCC-arvojen ilmeneminen spektrogrammina ajan yli sekä niiden esiintymistiheydet taajuusalueittain histogrammina. Skaalatuista MFCC-spektrogrammeista on huomattavissa samat piirteet kuin raakasignaaleista ja raakasignaalin spektrogrammeista: Maadoituskytkimellä on selkeästi nolasta poikkeavat MFCC-arvot yhden ja seitsemän sekunnin kohdalla, jolloin signaalista kuuluu mikrofonin päälle- ja pois-ääni. Tällä välillä MFCC-arvot ovat kaikilla taajuusalueilla molempien laitteiden osalta melko alhaisia, sillä kuten kuvan 25 spektrogrammeista voidaan huomata, ei äänen intensiteetissä ole merkittäviä piikkejä.

Kuvan 29 erottimien ja maadoituskytkimien moottorien äänien MFCC-arvojen histogrammista voidaan huomata selkeä eroavaisuus laitetyyppien välillä. Maadoituskytkimen eri taajuusalueet saavat selkeästi tasaisemmin MFCC-arvoja koko tarkastelualueella siten, että alhaisemmilla taajuuskaistaleilla arvot ovat lähempänä otoksen keskiarvoa. Johdopäätöksessä on huomioitava, että erittäin korkeat MFCC-arvot, jotka johtuvat mikrofonin äänistä, on jätetty tarkastelualueen ulkopuolelle. Erottimen kohdalla MFCC-arvojoukot yksittäisellä taajuusalueella ovat selkeästi toisistaan erillään, vaikka kokonaisuudessaan kaikkien MFCC-arvojen jakauma muistuttaakin etäisesti normaalijakaumaa.

## 6.6 Erottimen ja maadoituskytkimen vaihteiston äänisignaali

Erottimien ja maadoituskytkimien vaihteistoon liittyen voidaan tehdä päätelmiä vaihteiston yhteyteen kiinnitetyn mikrofoniin nauhoittamasta äänisignaalista. Vaihteistoon liittyen tunnistettiin luvussa 5.3 seuraavia tunnuslukuja:


- Tehollisarvo
- Huipusta huippuun -arvo
- Huipukkuus
- Huippuarvo
- Energiasuhde
- FM0
- FM4
- NA4\*



**Kuva 30.** Erottimen ja maadoituskytkimen vaihteistojen raakasignaalit

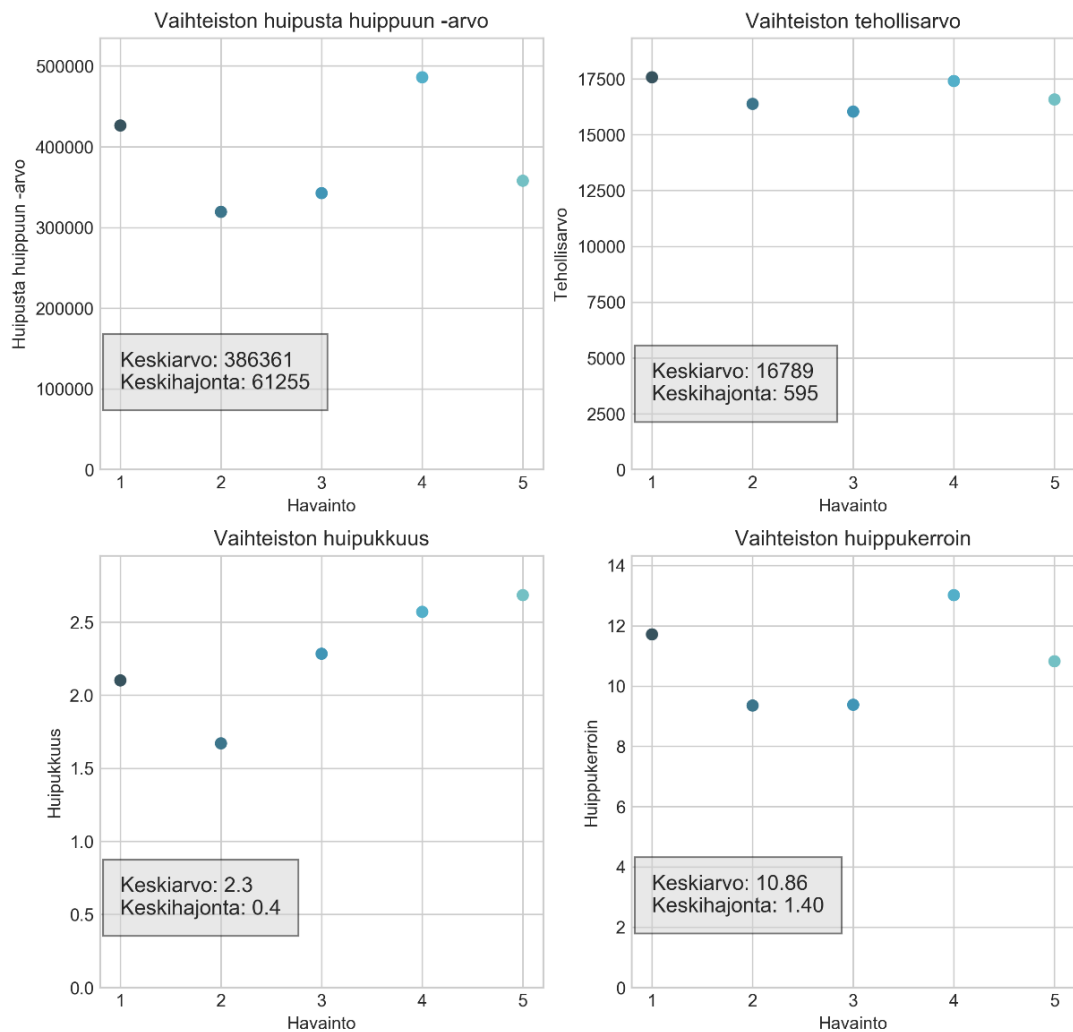
Kuvassa 30 on esitetty erottimen ja maadoituskytkimen vaihteiston toiminnasta nauhoitetun äänitiedoston raakasignaali. Signaalista voidaan nähdä kyseisen ohjaustapahtuman alkavan molemmilla laitteilla yhden sekunnin kohdalla ja päättyvän noin 6,5 sekunnin kohdalla. Näissä kohdissa näkyvät piikit ovat mikrofoniin käynnistymisestä ja sammumisesta syntyviä ääniä, eivätkä ole relevantteja vaihteiston analyysin kannalta. Tämän lisäksi erottimen raakasignaalista voidaan havaita melko pitkäkestoinen negatiivinen piikki neljän ja viiden sekunnin välillä. Kyseinen piikki on peräisin mikrofoniin nauhoittamasta valokaaren äänestä, joka tapahtuu toisaalla laitteistossa vaihteiston toiminnan aikana. Valokaari ei kuitenkaan ole relevantti vaihteiston toiminnan kannalta, joten se on syytä jättää huomiotta tunnuslukujen laskennassa. Tässä työssä ei oteta kantaa miten epärelevanttien piikkien havaitseminen ja irrottaminen analysoitavasta signaalista tulisi kestävässä analytiikkaratkaisussa toteuttaa. Tunnuslukujen laskentaa varten raakasignaalista leikattiin pois mikrofoniin käynnistymisääni ja tätä edeltävä hiljaisuus, valokaaren äänet ja mikrofoniin sulkeutuminen sekä sitä seuraava hiljaisuus. Jäljelle jääneet signaalin osat liitettiin

yhteen. Kuvassa 31 on esitetty tunnuslukujen laskennassa käytetyt prosessoidut esimerkit erottimen ja maadoituskytkimen raakasignaaleille.



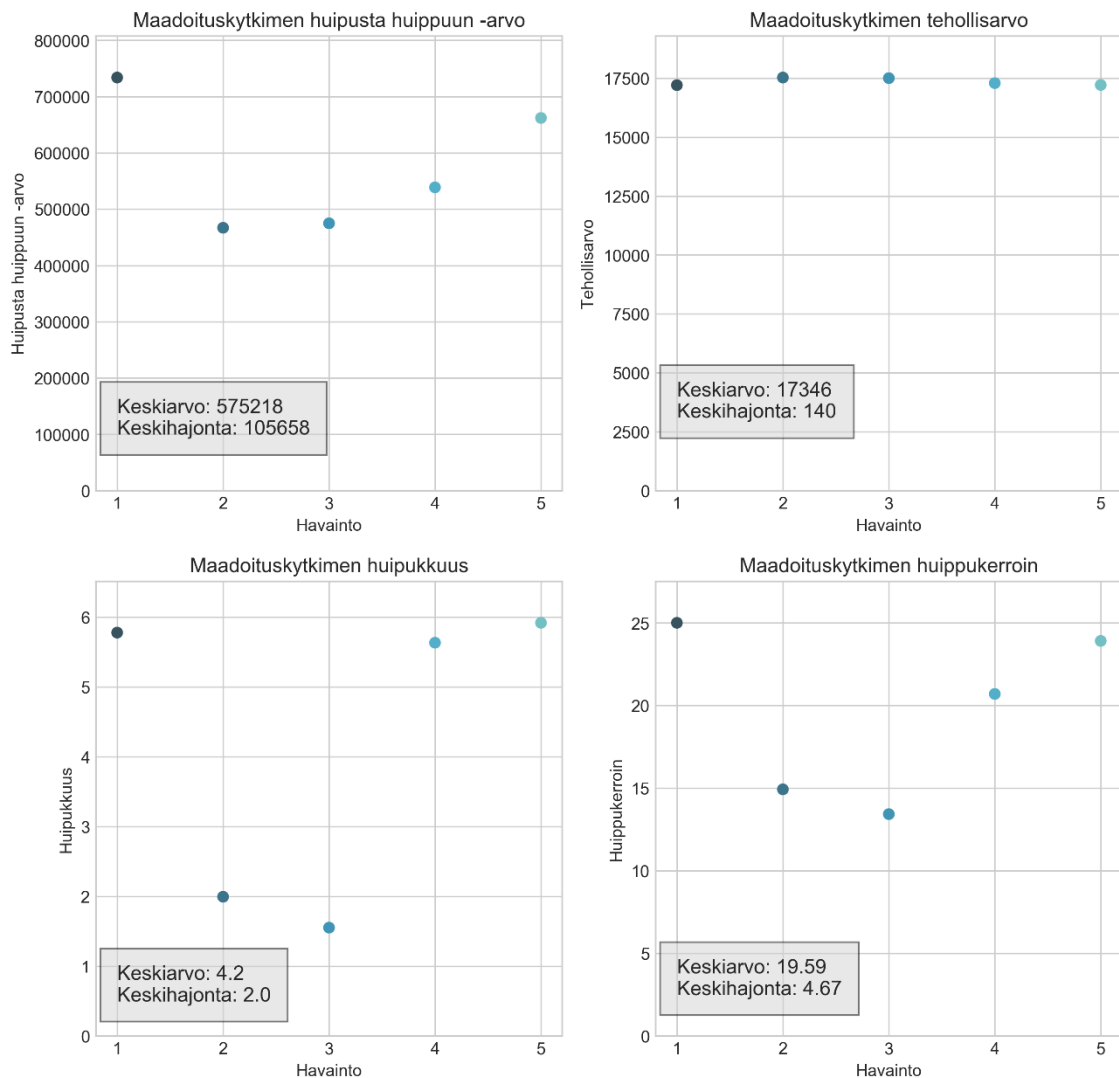
**Kuva 31.** Erottimen ja maadoituskytkimen vaihteiston prosessoitu raakasignaali

Erottimen vaihteistolle voidaan laskea ohjelman 8 avulla vastaavat tunnusluvut kuin katkaisijan iskunvaimentimelle eli tehollisarvo, huipusta huippuun –arvo, huipukkuus ja huippuarvo. Nämä tunnusluvut viidelle saman erottimen ohjaukselle ovat nähtävillä kuvassa 32.



**Kuva 32.** Erottimen vaihteiston tunnusluvut esimerkkitalalle

Kuvassa 32 näkyville tunnusluville saadaan seuraavat laskennalliset variaatiokertoimet: tehollisarvolle 3,54, huipusta huippuun -arvolle 15,9, huipukkuudelle 15,9 ja huippukertoimelle 12,9. Variaatiokertoimien perusteella tehollisarvon tunnusluvut ovat säännöllisiä kyseisessä otoksessa. Luotettavien tuloksien saaminen edellyttäisi kuitenkin tunnuslukujen laskentaa huomattavasti suuremmalle otoskoolle. Variaatiokertoimen perusteella voidaan tehdä alustavia johtopäätöksiä siitä, voidaanko esitetyn tunnusluvun perusteella arvioida laitteen kuntoa. Olettaessa laitteet hyväkuntoiseksi pitäisi kuvaavan tunnusluvun otosten tuottaa alhainen variaatiokerroin. Variaatiokertoimen laskeminen ilman minkäänlaista luokittelua saattaisi tuottaa liian suurta vaihtelua. Esimerkiksi jakamalla laitteet valmistajakohtaisesti tai eri elinkaaren vaiheessa oleviin laitteisiin, voitaisiin mm. variaatiokertoimen avulla pystyä tunnistamaan kuinka säännöllisiä esitetyt tunnusluvut ovat olettaessa tällä hetkellä dataa tuottavat laitteet hyväkuntoiseksi. Kuvassa 33 on laskettu vastaavat tunnusluvut maadoituskytkimen vaihteistolle.



**Kuva 33.** Maadoituskytkimen vaihteiston tunnusluvut esimerkkitalalle

Kuvassa 33 esitettyjen tunnuslukujen keskiarvojen ja keskihajontojen avulla voidaan laskea seuraavat variaatiokertoimet: huipusta huippuun arvolle 18,4, tehollisarvolle 0,81, huipukkuudelle 47,1 ja huippukertoimelle 23,8. Tehollisarvon voidaan huomata olevan

otoksilla hyvin säännöllinen tunnusluku sekä erottimelle että maadoituskytkimelle. Huippukkuuden ja huippukertoimen variaatiokertoimet vaikuttavat korkeilta, joka voi tarkoittaa tunnuslukujen huonoa kuvaavuutta laitteen kunnosta. Tarkastelemalla havaintoja huomataan kuitenkin, että molemmille tunnusluville kaksi havaintoa poikkeavat selvästi muista. Tämä tarkoittaa, että havainnot 1 ja 2 ovat olleet erilaisia ohjauksia kuin muut havainnot. Porautuessa ohjausten metadataan huomataan näiden kahden ohjauksen tapah-tuneen huhtikuussa, kun kaksi aiempaa ohjausta olivat suoritettu joulukuussa. Tunnuslu-kujen eroavaisuus voi siis tässä tilanteessa johtua toisistaan poikkeavista sääolosuhteista, jolloin vaihteisto kuormittuu eri tavalla. Maadoituskytkimen ja erottimen vaihteistojen esimerkkiotokselle lasketut tunnusluvut eroavat toisistaan merkittävästi, joka tarkoittaa, että laitteiden samankaltaisesta toimintaperiaatteesta huolimatta, ne vaativat omat mal-linsa kunnonvalvontaan. Nämä erot voivat johtua toiminnan eroavaisuuksien lisäksi esi-merkiksi mittausasetelmasta ja signaalien prosessoinnista.

```
# Energiasuhde
# dif_signal = erosignaali, res_signal = jäännössignaali
def get_energy_ratio(signal, dif_signal):
    # Signaalien tehollisarvojen osamäärä
    dif_sig_rms = np.sqrt(np.mean(np.array(dif_signal)**2))
    sig_rms = np.sqrt(np.mean(np.array(signal)**2))
    return dif_sig_rms / sig_rms

# FM0
def get_fm0(signal, res_signal):
    peak_to_peak = (max(signal) - min(signal))
    # Rasteritaajuuksien kerrannaisten tehollisarvojen summa
    res_rms_sum = 0
    for harmonic in res_signal:
        res_rms_sum += np.sqrt(np.mean(np.array(harmonic)**2))
    return peak_to_peak / res_rms_sum

# FM4
def get_fm4(signal, dif_signal):
    dif_mean = np.mean(dif_signal)
    return len(signal)*np.sum((signal - dif_mean)**4) /
        ((np.sum(signal - dif_mean)**2)**2)

# NA4*
# ok_res_signal sisältää hyväkuntoiseksi tiedetyn vaihteiston jäännössignaalin
def get_na4(res_signal, ok_res_signal):
    res_mean = np.mean(res_signal)
    ok_res_var = np.var(ok_res_signal)
    return (len(res_signal)*np.sum((res_signal-res_mean)**4))/(ok_res_var**2)
```

### **Ohjelma 9.** *Vaihteiston tunnuslukujen laskeminen*

Ohjelmassa 9 on esitetty luvussa 5.3 tunnistettujen vaihteiston tunnuslukujen laskentaan vaadittavat ohjelmakoodit. Kyseisten tunnuslukujen laskeminen ei tämän hetkisillä tie-doilla onnistu, vaan edellyttää jäännös- ja erosignaalien määrittämistä alkuperäisen raa-kasignaalin lisäksi. Jäännössignaalin määrittämisellä voidaan laskea NA4\*-tunnusluku ja tästä eteenpäin määrittämällä erosignaali mahdollistetaan energiasuhteen, FM0 ja FM4



tunnuslukujen laskenta. Jäännös- ja erosignaalien määrittämiseen ei tässä työssä oteta kantaa, sillä se edellyttää esimerkiksi vaihteiston hammaspyörän kierrosnopeuden ja hammasrattaan hammasäärän tietämistä. Nämä tiedot eivät tätä tutkimusta varten olleet saatavilla Kymin mittausasetelmasta.

## 6.7 Ohjausyksikön tunnusluvut

Ohjausyksikön tunnuslukuja tunnistettiin kyseisellä mittausasetelmalla olevan lämpötila ja ilmankosteus. Näiden selvittäminen on hyvin suoraviivaista, sillä ohjausyksikköön on asennettu lämpötila- ja kosteussensorit. Mitään sen suurempaa laskentaa ei siis vaadita, vaan olennaisen datan erottaminen saapuvasta tiedostomuodosta riittää tunnuslukujen saamiseksi käyttöön.


Ohjausyksikön olosuhteisiin liittyvä data saadaan antureista pilviympäristöön json-tiedostona. Sekä lämpötila että ilmankosteus tulevat saman tyyppisinä datariveinä ja rivin metatiedoista voidaan tunnistaa, kumpi mittaus on kyseessä. Tunnuslukuarvon lisäksi esimerkkikoodissa erotetaan arvon tyyppi, eli onko kyseessä lämpötila vai ilmankosteus, ja mittausaika.

```
def parse_humidity_and_temperature(dir_path):
    # Luodaan tyhjät dict-rakenteet datan tallettamiselle
    humidities = {}
    temperatures = {}
    for file in os.listdir(dir_path):
        # Tarkistetaan tiedoston tyyppi
        if file.endswith(".json"):
            with open(file) as jsonfile:
                data = json.load(jsonfile)
                # Halutut arvot ovat datapisteen arvo ja luontiajankohta
                values = [data["value"], data["created"]]
                if (data["descriptor"] == "temperature"):
                    temperatures[data["id"]] = values
                elif (data["descriptor"] == "humidity"):
                    humidities[data["id"]] = values
    return humidities, temperatures
```

### *Ohjelma 10. Lämpötilan ja ilmankosteuden erottaminen json-tiedostosta*

Ohjelmassa 10 esitetyn funktion avulla saadaan omat pythonin dictionary-tietorakenteet lämpötilalle ja ilmankosteudelle, jotka pitävät sisällään kaikki tunnuslukuun liittyvät mittaukset. Funktiota kutsuttaessa parametriksi annetaan tiedostopolku, jossa json-tiedostot sijaitsevat ja vastaukseksi se palauttaa ilmankosteudelle ja lämpötilalle omat dictionary-tietorakenteet. Tietorakenteen avaimena on jokaiselle mittaukselle ominainen id ja arvona mittauksen arvo sekä mittausaika listarakenteena.

Kuvassa 34 on visualisoituna esimerkkinä käytetyt viisi mittauksetulosta sekä ilmankosteudelle että lämpötilalle. Vasemman puoleisessa kuvaajassa on nähtävillä ilmankosteudet mittauskohtaisesti ja oikean puoleisessa puolestaan lämpötilat.



**Kuva 34.** Ohjausyksikön ilmankosteus- ja lämpötila-arvot

## 7. TULOKSET JA POHDINTA

Työn viimeisessä luvussa esitetään pohdintaa saavutetuista löydöksistä ja tiivistetään tutkimuksen keskeiset tulokset. Ensimmäisessä alaluvussa, eli yhteenvedossa, käydään läpi tutkimuksen tulokset kahteen alatutkimuskysymykseen ja tiivistetysti tutkimuksen pää-tutkimuskysymykseen. Pää-tutkimuskysymykseen esitetään laajemmin pohdintaa kahdessa seuraavassa alaluvussa jakaen tämä teoreettiseen kontribuutioon ja käytännön vaikutuksiin. Tämän jälkeen neljännessä alaluvussa tutkimuksessa saavutettuja tuloksia arvioidaan ja tarkastellaan näiden yleistettävyyttä. Luvun lopuksi käsitellään tutkimuksen pohjalta nousseet jatkotutkimuskohteet.

### 7.1 Yhteenveto

Tutkimuksen tarkoituksena oli ymmärtää IoT-anturoinnin mahdollistamaa mekaanisten laitteiden ennustavaa kunnossapitoa ja kunnossapidon siirtymään kohti dataohjautuvuutta vaikuttavia tekijöitä. Alatutkimuskysymyksissä tutkittiin Fingridin Kymin kytkinase-malla olevaa IoT-anturointia. Tähän liittyvän tutkimustyön pohjalta voidaan tiivistää vas-taukset näihin kahteen alatutkimuskysymykseen sekä esitetyn teoriataustan avulla myös päätutkimuskysymykseen.

*Mitä laitteiden kuntoa kuvaavia tunnuslukuja katkaisijoihin, maadoituskytkimiin ja erot-timiin liittyy, joita voidaan tunnistaa Fingrid Oyj:n Kymin sähköaseman IoT-mittaroin-nista?*

Tutkimuksessa tarkasteltiin sähkölaitteiden puolesta katkaisijoita, erottimia ja maadoitus-kytkimiä. Laitteista erottimien ja maadoituskytkimien todettiin vastaavan niin läheisesti rakenteeltaan toisiaan, että kirjallisuuskatsauksessa niitä käsiteltiin yhtenä kokonaisuutena. Tunnuslukuja laskettiin kaikille laitetyypeille erikseen. Fingridin Kymin kytkinase-man mittaustilanteesta anturoitavia mekaanisia komponentteja olivat seuraavat: katkaisi-joiden, erottimien sekä maadoituskytkimien moottorit, katkaisijoiden iskunvaimentimet sekä erottimien ja maadoituskytkimien vaihteistot. Tämän lisäksi mittarointia tehtiin lait-teistojen ohjausyksiköiden olosuhteista.

Kytkinlaitteiden moottoreihin liittyen kerättiin kahta erilaista dataa, josta tunnuslukuja pystyttiin laskemaan: moottorin virtasignaali eli moottorin käyttämä virta sekä mikrofo-nilla nauhoitettu äänitiedosto moottorin toiminnasta. Virtaprofiilista pystyttiin laskemaan seuraavia tunnuslukuja: moottorin virrankulutus, katkaisijan viritysaika ja erottimen tai maadoituskytkimen ohjausaika. Moottorin virrankulutuksen perusteella kunnonvalvonta perustuu oletukseen, että epäkuntoinen laite vaatii toimiakseen suuremman virtamäärän kuin normaalisti toimiva. Viritys- tai ohjausajan laskeminen kunnon arvioinnin näkökul-

masta perustuu olettamukseen, että laitteiston toimiessa väärin sen ohjausaika alkaa pidentyä merkittävästi. Ohjauksen tai virityksen keston tarkastelussa on otettava huomioon laitteen elinkaaren vaihe ja vallitsevat olosuhteet, joilla on merkittävä vaikutus ohjaukseen kuluneeseen aikaan. Edellä mainittujen tunnuslukujen lisäksi moottorien virtaprofiilien vertailuun liittyen tunnistettiin dynaaminen aikasovitus etäisyys. Tämä mahdollistaa esimerkiksi saman laitteen kahden eri ohjauksen virtakäyrien vertaamisen, jolloin laitteen kulumista voidaan arvioida.

Moottorien toiminnan äänisignaalin analysoiminen edellytti signaalin muuntamista aikatasa- taajuustasoon. Signaalin ikkunoinnilla ja yksittäisten spektrien laskemisella luotiin ohjauksen äänen spektrogrammi visuaalista tulkintaa varten. Yksittäisille spektreille laskettiin tunnuslukuja, jolloin koko äänisignaalille saatiin tunnuslukujoukkoja. Näitä spektrin tunnuslukuja olivat: spektrin keskipiste, spektrin vinous, nollanylitystaajuus ja MFCC. Spektrin keskipistettä ja vinoutta käytetään kuvaamaan spektrin muotoa. Nollanylitystaajuus kertoo kuinka usein audiosignaali ylittää matemaattisen koordinaatiston x-akselin. MFCC puolestaan on yleisesti puheentunnistuksessa, mutta myös jonkin verran viantunnistuksessa käytetty tunnusluku. Tutkimuksessa ei otettu kantaa siihen, miten näitä tunnuslukujoukkoja tulisi vertailla toisiinsa.

Katkaisijan iskunvaimentimen toimintaan liittyen nauhoitettiin äänisignaalia, jonka perusteella sen toimintaa ohjauksen aikana voidaan analysoida. Iskunvaimentimen toiminnan tulkitsemiseen tunnistettiin seuraavia värähtelysignaalin tunnuslukuja: tehollisarvo, huipusta huippuun –arvo, huipukkuus ja huippukerroin. Tehollisarvon avulla voidaan mitata yleistä äänitasoa, huipusta huippuun –arvolla signaalin ääriarvoja, huipukkuudella värähtelysignaalin amplitudia ja huippukertoimella signaalin muotoa.

Eroittimen ja maadoituskytkimen vaihteistoon liittyen nauhoitettiin toiminnasta syntyvää ääntä. Vaihteistoon liittyen voidaan tunnistaa samat värähtelysignaalin tunnusluvut kuin katkaisijan iskunvaimentimeen eli tehollisarvo, huipusta huippuun –arvo, huipukkuus ja huippukerroin. Näiden tunnuslukujen lisäksi vaihteistolle spesifejä tunnuslukuja tunnistettiin seuraavia: energiasuhde, FM0, FM4, NA4\*. Energiasuhde vertaa erosignaalin ja varsinaisen signaalin tehollisarvoja, FM0 on merkittäviä hammasvioittumisia havaitseva tunnusluku, FM4 yksittäisen hammasrattaan hampaan vioittumista havaitseva tunnusluku, ja NA4\* puolestaan useamman hampaan vioittumiseen keskittyvä tunnusluku. Vaihteistolle spesifien tunnuslukujen laskeminen edellyttää ero- ja jäännössignaalien määrittämistä.

Kytkeinlaitteiden tunnuslukujen lisäksi mittarointia tehdään laitteiden ohjausyksiköstä, jonka kautta ohjaukset tapahtuvat. Ohjausyksikköön on asennettuna lämpö- ja kosteusmittari. Tätä kautta saadaan tarkkailtua ohjausyksikön olosuhteita eli lämpötilaa ja ilman kosteutta.

*Miten edellä tunnistettuja tunnuslukuja voidaan tuottaa kytkinasemalta kerätystä data-aineistosta?*

Ensimmäisen tutkimuskysymyksen pohjalta tunnistettujen tunnuslukujen määrittäminen Fingridin Kymin kytkinasemalta mitatusta datasta python-ohjelmointikielen avulla esiteltiin luvussa 6. Moottorin virtasignaalista laskettava viritysaika saadaan johdettua tunnistamalla virransyötön alku- ja loppupiikki sekä laskemalla näiden välillä kuluva aika. Tämä on nähtävillä ohjelmassa 2. Moottorin virrankulutus vastaa varauksen siirtymää tarkastellussa aikaikkunassa, ja se voidaan määrittää laskemalla summaintegraali virtasignaalista ajan yli kuten ohjelmassa 3 esitetään. Dynaamisen aikasoitus etäisyyden laskentaan vaadittava algoritmi esiteltiin python-kielen funktiona ohjelmassa 4.

Moottorien äänisignaalin ikkunointi, joka edellytetään spektrin tunnuslukujen laskentaan, on esitetty ohjelmassa 5. Työssä ei otettu kantaa analyysin kannalta optimaaliseen ikkunan pituuteen tai vierekkäisten ikkunoiden yhteisille datapisteille. Spektrogrammin laskeminen ja visualisointi esitettiin ohjelmassa 6. Spektrin keskipiste, spektrin vinous, nollanylitystaajuus ja MFCC-arvojen laskenta on esitetty ohjelmassa 7.

Katkaisijan iskunvaimentimen äänisignaalista laskettavien tunnuslukujen, eli tehollisarvon, huipusta huippuun –arvon, huippukkuuden ja huippukertoimen, laskeminen ohjelmakoodilla on esitetty ohjelmassa 8. Samat yleiset värähtelysignaaliin liittyvät tunnusluvut voidaan laskea myös erottimien ja maadoituskytkimien vaihteistoille. Vaihteistolle spesifit tunnusluvut, eli energiasuhde, FM0, FM4, NA4\*, edellyttävät lisätietoa tutkittavista laitteista, esimerkiksi vaihteiston hammasrattaiden hampaiden määrää. Tämän takia näitä ei voitu kerätystä data-aineistosta laskea. Ohjausyksikön olosuhteisiin liittyvän informaa-tion erottaminen datasta on esitetty ohjelmassa 10.

Asetettuun päätutkimuskysymykseen vastaaminen toimii tiivistyksenä koko tutkimukselle. Päätutkimuskysymyksessä tarkastelu tapahtuu myös yleisemmällä tasolla, vaikka havainnot ovatkin peräisin Fingridille tehdystä tapaustutkimuksesta.

*Miten IoT-anturoinnilla voidaan mahdollistaa mekaanisten laitteiden ennustava kunto-perustainen kunnossapito, ja mitä kunnossapidon siirtyessä dataohjattuun päätöksente-koon on otettava huomioon?*

Työssä tehdyssä tapaustutkimuksessa ennustavaa kuntoperustaista kunnossapitoa varten tunnistettiin sähköaseman kytkinlaitteiden mekaanista kuntoa kuvaavia tunnuslukuja. Tunnuslukuja tunnistettiin liittyen kytkinlaitteiden moottoreihin, katkaisijoiden iskunvaimentimiin sekä erottimien ja maadoituskytkimien vaihteistoihin. Näihin mekaanisiin komponentteihin liittyen nauhoitettiin toiminnasta syntyvää ääntä sekä moottoreista virran käyttöä. Kuntoa kuvaavia tunnuslukuja esitettiin virtaprofiiliin, äänispektriin ja äänen värähtelysignaaliin liittyen. Virtaprofiilille tunnusluvuiksi tunnistettiin ohjaustapahtuman kesto sekä virrankulutus. Äänispektriin liittyen tunnistettiin puolestaan spektrin keskipiste, spektrin vinous, nollanylitystaajuus ja MFCC-arvot. Äänen värähtelysignaalille

tunnistettiin tunnusluvuiksi katkaisijan iskunvaimentimelle tehollisarvo, huipusta huippuun –arvo, huippukkuus ja huippukerroin. Erottimen sekä maadoituskytkimen vaihteistolle tunnistettiin samat tunnusluvut kuin katkaisijan iskunvaimentimelle sekä tämän lisäksi seuraavat tunnusluvut: energiasuhde, FM0, FM4 ja NA4\*. Näiden laskemiseen edellytettävät ohjelmakoodit esitettiin tutkimuksessa ja saavutettuja tuloksia visualisoi- tiin. Esitelty tapaustutkimus toimii esimerkkinä ja pohjana muille samantyyllisille ennus- tavan kuntoperustaisen kunnossapidon siirtymille.

Kunnossapidon siirtyessä dataohjattuun päätöksentekoon on keskeistä ymmärtää, ettei muutos ole puhtaasti teknologinen, vaan se edellyttää päätöksentekijöiltä sitoutumista muutokseen ja valmiutta omaksua itselleen vieraita toimintatapoja. Sopeutumista vaativat niin organisaatiokulttuuri, johtamistapa, teknologia, vaadittu osaaminen kuin päätöksen- tekoprosessitkin. Kunnossapidon siirtymässä on keskeistä olla takertumatta liikaa alku- peräisiin ajatuksiin ja oltava valmis iteroimaan niin analyysia kuin myös analyysin lähtö- kohtia. Tarkoituksenmukaista ei ole kehittää analytiikkaa loputtomiin, vaan löytää ti- lanne, jossa saavutettava liiketoiminta-arvo ja syntyvät kustannukset ovat organisaatiolle optimaalisessa suhteessa.

## 7.2 Teoreettinen kontribuutio

Tämän tutkimuksen tuloksena saavutetut tunnusluvut kuvaavat kytkinlaitteiden tilaa tar- kastelemalla yksittäisiä mekaanisia komponentteja. Näiden pohjalta mahdollistetaan jat- kotutkimus, jossa voidaan selvittää tunnuslukujen hyvyys laitteen kunnon kuvaamisessa, ja täten tunnistaa ennustavassa kunnossapidossa käytettäviä parametreja. Tämä edellyttää laajemman data-aineiston läpikäymistä tai vaihtoehtoisesti uudentyyppisiä, rikkinäisillä komponenteilla tehtyjä, mittauksia kytkinasemilla. Luvussa 5 tunnistetut tunnusluvut ovat kuitenkin yleispäteviä, joten ne voidaan laskea myös toisilta mittausasemilta kerä- tystä ääni- tai virtasignaalista. Tunnuslukujen laskemisen mahdollisuus ei kuitenkaan vielä tarkoita, että tunnusluvut olisivat vertailukelpoisia keskenään. Liitettäessä muita kytkinasemia Fingridin IoT-verkostoon tulee tarkastella tapahtuuko tunnusluvuissa mer- kittäviä muutoksia johtuen eri valmistajien sähkölaitteista tai antureista. Eri kytkinase- milla myös esimerkiksi taustamelu tai sääolosuhteet voivat olla merkittävästi erilaisia, jolloin tunnusluvut eivät enää ole keskenään vertailukelpoisia, vaan vertailua on tehtävä pienemmissä populaatioissa kuten yhden laitevalmistajan tietyn kytkinaseman laitteiden kesken.

Keskeisenä analyysin lähtödatana toimiva äänisignaali on tietyllä tapaa hankala data- lähde, sillä siihen vaikuttaa merkittävästi anturin ympäristö, eli esimerkiksi se miten ää- nivärähtely heijastuu erilaisista pinnoista ja muodoista (Schuller 2013). Lisäksi mikrofoni nauhoittaa kaikkea kuuluvaa ääntä, jolloin mukaan tarttuu helposti myös muista kuin mi- tattavasta kohteesta syntyvää värähtelyä. Tällöin oleellisen signaalin erottaminen vaatii merkittävää prosessointia. (Rubhini & Ranjan 2017; Schuller 2013.) IoT-hankkeen jatkon kannalta onkin analysoitava esimerkiksi äänisignaalin toimivuutta kuntoluokittelussa.

Vastaavien tunnuslukujen laskeminen onnistuisi myös keräämällä muulla tavalla laitteiden värähtelyä, esimerkiksi kiihtyvyysantureilla. Tällöin signaalin alkuperä olisi todennäköisemmin tarkasteltava kohde ja esiprosessointi vaatisi vähemmän työtä.

Analysoitaessa yleisesti kunnonhallinnan siirtymistä dataohjattuun päätöksentekoon on tärkeää ymmärtää mitä vaiheita muutos edellyttää. Suhteutettaessa tätä tapaustutkimusta luvussa 4 esiteltyihin analytiikan prosessimalleihin voidaan tunnistaa käsittelyssä olevan prosessimallien alkupään vaiheita. Shearerin (2000) CRISP-DM prosessimallin näkökulmasta tämä tutkimus keskittyy kolmeen ensimmäiseen vaiheeseen: liiketoimintaymmärrykseen, datan ymmärrykseen ja datan valmisteluun. Visuaalisen analytiikan prosessimallin näkökulmasta keskittyminen on datassa, sen käsittelyssä, kartoituksessa, visualisoinneissa ja tiedonlouhinnassa. Tutkimuksen tavoitteena ei ollut käydä läpi koko analyysiprosessia, vaan luoda edellytykset ja tarvittava ymmärrys prosessin ymmärtämiselle, mallinnukselle ja tulosten hyödyntämiselle. Tutkimus itsessään tuottaa visuaalisen analytiikan prosessimallissa mainittuja visualisointeja, joilla jatkotutkimukseen liittyvä vikatiilan tunnistavan mallin kehitys mahdollistetaan.

Luvussa 4 esiteltyjen Davenportin (2014) analytiikan tasojen ja Davenportin (2016) IoT-analytiikan tasojen puolesta tämä tutkimus keskittyi kuvailevaan ja diagnostiiviseen analytiikkaan. Tavoitteena oli ymmärtää olemassa olevaa tilannetta ja selittää datan pohjalta havaittavia ilmiöitä. Kuvailevan ja diagnostiivisen IoT-analytiikan rooli on olennainen lähtökohta myös korkeammille analytiikan tasoille, sillä alemmilla tasoilla tehty havainnot ja löydökset toimivat pohjana korkeamman arvon analytiikan rakentamiselle. Kokonaisuudessaan Fingridin kunnossapitomallin siirtymän voidaan nähdä tavoittelevan tällä hetkellä ennustavan IoT-analytiikan tasoa, jolla mahdollistetaan datan pohjalta laitteiston vikaantumisen tunnistus jo ennen kuin se pääsee vaikuttamaan systeemin toimintaan. Tämä Davenportin (2016) IoT-analytiikan taso voidaan rinnastaa Barberan et al. (1996) sekä Leen & Wangin (2008) käyttämään ennustavan kunnossapidon tasoon. Pidemmällä aikavälillä tavoitteena on siirtyä ohjaavaan analytiikkaan, jossa datan pohjalta pystytään suoraan antamaan toimintasuosituksia kunnossapidon ammattilaisille ja tehostamaan kunnossapitoprosessia. Tällä hetkellä kuitenkin tehdään diagnostiivista IoT-analytiikkaa ja luodaan valmiuksia ennustavalle analytiikalle ja ennustavalle kunnossapidolle.

Analytiikan prosessimallien ja IoT-analytiikan tasojen pohjalta on syytä kiinnittää huomiota analytiikan kehityksen luonteeseen. Analytiikka soveltuu luonnollisesti yhteen ketterien toimintatapojen kanssa, joissa korostuvat nopeat muutoksiin reagoinnit (Larson & Chang 2016). Tämä ketterä luonne näkyy niin analytiikan prosessimallien CRISP-DM:n ja visuaalisen analytiikan iteratiivisuudessa kuin myös Davenportin (2016) IoT-analytiikan tasoissa, joissa tarkoituksena on jatkuvasti kehittää organisaation toimintaa pyrkien korkeamman arvontuotannon tasoille. Ketterät ja muuttuvat toimintatavat eivät tule luonnostaan kunnossapitoyksikön toimijoille, jotka ovat tottuneet säännölliseen ja tarkasti suunniteltuun työntekoon. Analytiikkaan liittyvien toimintatapojen omaksuminen vaatii-kin erityistä työpanosta ja sitoutumista kunnossapitomallin siirtymän onnistumiseksi.

Muutettaessa kunnossapitomallia kohti dataohjattua päätöksentekoa arvonluonnissa korostuvat McAfee & Brynjolfssonin (2012) nostamat tekijät muutoksen onnistumiselle. Olennaista on ymmärtää, että kyseessä ei ole pelkästään tekninen ratkaisu. Teknologian lisäksi muutos edellyttää niin organisaatiokulttuurin, henkilöstössä tarvittavan osaamisen, johtamistavan kuin myös päätöksentekoprosessien uudistamista. Päättäjien on aidosti sitouduttava käyttämään tarjottua teknologiaa, jotta datasta ei tule vain väline perustella omia intuitioon pohjautuvia päätöksiä. (McAfee & Brynjolfsson 2012.) Fingridin kunnossapidon kohdalla tilanne on hieman tavallisesta analytiikan tuomisesta päätöksentekoon poikkeava, sillä IoT-anturoinnin ja analytiikan tarjoamat mahdollisuudet uusivat prosesseja erityisen radikaalisti. Aiemmin kunnossapidon päätöksentekijöillä ei ole ollut reaaliaikaiseen verrattavaa näkyvyyttä kytkinasemille, vaan päätökset ovat pohjautuneet määritettyihin aikatauluihin tai jo tapahtuneisiin vikaantumisiin. IoT:n mahdollistama anturointi tuo uuden toimintatavan, eikä siis niinkään muokkaa olemassa olevia. Aluksi toimintatavat tulevat nykyisten rinnalle, mutta pidemmällä aikavälillä ne voivat korvata ne kokonaan. Tämä voi muodostua erityisen haastavaksi, sillä Kefalidou et al. (2015) sekä Golightly et al. (2017) korostavat muutoksen olevan erityisen hankalaa toimialoilla, jossa infrastruktuurin elinkaari on pitkä. Fingridin kytkinlaitteet voidaan laskea tähän luokitukseen. Haasteen ratkaisuksi dataohjatun ennakoivan kunnossapidon mahdollistama teknologia tulee suunnitella siten, että suosituksen perustelut ovat läpinäkyviä ja teknologia vastaa käyttäjien todelliseen tarpeeseen (Morison et al. 2016).

Fingridin tapaustutkimuksen teoreettisesta kontribuutiosta voidaan tehdä nostoja myös yleisemmälle tasolle. IoT-hankkeen alussa valitut datan keräävät anturit rajaavat tarkasti tutkimuksen suuntaa. Tämän takia myös datalähteissä on huomioitava analytiikan iteraatiivisuus ja säilytettävä mahdollisuus myös mittaustilanteen muutoksille. Erityisesti hyödynnettäessä äänidataa, on kiinnitettävä huomiota ympäristöstä syntyvään kohinaan sekä tämän vaikutuksiin tehtävälle analyysille. Toteutettaessa analytiikkaprojektia on ymmärrettävä analytiikan kehityksen luonne, tarkoitus ja siihen liittyvät erityispiirteet. Tämä voi aiheuttaa erityisiä haasteita organisaatioissa, jotka ovat tottuneet perinteisempiin, tarkasti jäsenneltyihin, työtapoihin.

### 7.3 Käytännön vaikutukset

Nostettaessa esille tutkimuksen pohjalta nousseita käytännön huomioita ja löydöksiä, on hyvä lähteä liikkeelle tutkimuksen suunnan määränneestä alkutilanteesta. Tapaustutkimuksen suuntaa ja löydöksiä ohjasivat voimakkaasti alussa tunnistettu Fingridin mittaustilanne Kymin sähköasemalla. Tämä tarkoittaa millaisia ja miten asetettuja antureita, eli datan kerääjiä, kytkinasemalla on. Tässä kohtaa on syytä arvioida tunnuslukujen valossa ovatko kaikki Kymin kytkinasemalle asennetut anturit tarpeellisia, vai voidaanko samat tulokset saavuttaa pienemmällä määrällä antureita. Toisena pohdintakohteena, joka selkeytyy jatkotutkimuksen myötä, on, tarjoavatko nykyiset anturit tarvittavia tunnuslukuja, vai tarvitaanko mahdollisesti uusia tai erilaisia antureita.



Kustannusoptimointi on kaiken kaikkiaan keskeisessä roolissa edistettäessä Fingridin kunnossapitomallin siirtymää ennustavaan kunnossapitoon. Tavoitetilassa halutaan saada mahdollisimman tarkka käsitys laitteiden kunnosta ja huoltotarpeesta minimaalisilla kustannuksilla. Vaikka anturit ja datan tallennus ovat jo nykyään edullisia, ei dataa ole järkevää kerätä, ellei sitä ole tarkoituksena hyödyntää mitenkään. Pitkällä aikavälillä pienetkin säästöt jatkuvissa kustannuksissa voivat muodostua tuntuviiksi. Ennen tunnuslukujen ja niiden hyvyyden määrittystä on mittarointia kuitenkin haastavaa kehittää ja anturien asennuksia suunnitella kustannustehokkaasti. Koko lähtökohta IoT-anturoinnille on kustannustehokkaan ratkaisun löytäminen, sillä useat laitevalmistajat tarjoavat omia älykkäitä kytkinlaitteitaan, mutta nämä ovat usein huomattavan kalliita eivätkä kytkinlaitevalmistajien monitorointien jälkiasennukset ole mahdollisia olemassa olevaan Fingridin laitekantaan järkevillä kustannuksilla.

Tarkasteltaessa taustateoriassa esiteltyä Leen et al. (2008) kunnossapidon maturiteettitasoja voidaan Fingridin nykyisen kunnossapidon tunnistaa olevan yhdistelmä reaktiivista ja ehkäisevää kunnossapitoa. Tavoitteena on kytkinlaitteiden IoT-analytiikan avulla siirtä kokonaisvaltaisemmin kuntoperustaiseen ennustavaan kunnossapitoon ja tämä tutkimus luo pohjaa siirtymän edellyttämälle tekniselle toteutukselle. Jatkossakin reaktiivinen kunnossapito tulee säilymään osana Fingridin kunnossapitomallia. Esimerkiksi luonnonilmiöistä johtuviin häiriöihin, kuten salamaniskujen aiheuttamiin laitehajoamisiin, ei ole mahdollista varautua ennustavasti. Pohdittaessa dataohjatun päätöksenteon mahdollistamista Fingridin kunnossapitoyksikölle on syytä miettiä, miten laskennallisia tunnuslukuja tulisi tarjota osaksi päätöksentekoprosessia.

Vain harvat tutkimuksessa tunnistetuista tunnusluvuista kertovat kytkinlaitteiden asiantuntijoiden substanssiosaamisella mitään laitteen toiminnasta. Tällaisia, kunnossapidon asiantuntijoille tuttuja tunnuslukuja, ovat esimerkiksi moottorin virrankäyttö tai katkaisijan viritysaika sekä erottimen ja maadoituskytkimen ohjausaika. Suurin osa tunnistetuista tunnusluvuista liittyvät äänispektreihin tai värähtelysignaaliin. Näiden laskennallisten arvojen tulkinta edellyttää perehtymistä signaalinkäsittelyyn ja akustiikkaan, eivätkä tunnusluvut tällaisina lukuarvoina ole informatiivisia kytkinlaitteiden kunnossapidosta vastaaville. Tulosten viennissä käytäntöön onkin syytä selvittää loppukäyttäjien, eli kunnossapidon ammattilaisten, kanssa, miten dataa halutaan käsitellä päätöksenteon tukena. Datat pohjalta voidaan esimerkiksi tarjota hälytyksiä määriteltyjen raja-arvojen ylittyessä, tai vaihtoehtoisesti tilannetta kuvaavia visualisointeja, joiden perusteella päätöksentekijät voivat perustaa päätöksensä tapahtuneeseen dataan. Visualisoinneissa on vastaava haaste kuin laskennallisissa tunnusluvuissa, eli käyttäjien on opittava ymmärtämään ja hyödyntämään niitä. Tämän haasteen ylittämiseksi dataohjatun päätöksenteon käyttöönottoon on asetettava merkittäviä panostuksia, jotta teknisen toteutuksen mahdollisuudet saadaan tuottamaan liiketoiminta-arvoa.

Teoreettisessa kontribuutiossa nostettuun analytiikan ketterään luonteeseen on keskityttävä myös Fingridin siirtymässä dataohjattuun ennustavaan kunnossapitoon. Ennustavan

kunnossapidon analytiikasta on tehtävä jatkuva toiminto enemmän kuin kertaluonteinen projekti. Tällöin mahdollistetaan jatkuva korkeamman liiketoiminta-arvon tuottaminen, eikä vain kertaluontoinen ja pistemäinen ratkaisu yksittäiseen ongelmaan. Toimintatapojen muutos ei ole kuitenkaan helppo perinteisempiin toteutusmalleihin tottuneille henkilöille tai koko organisaatiolle, joten sen onnistuminen vaatii merkittävää työpanosta. Kunnossapidon yksikössä on siis huolehdittava, ettei toteutettava tekninen ratkaisu jää yksittäiseksi apukeinoksi, vaan se toimii lähtökohtana merkittävämmälle toiminnan kehitykselle.

Tutkimuksen tuloksena esitetyt käytännön vaikutukset ovat pitkälti suunnattu tapaustutkimuksen kohteena tarkasteltuun Fingridiin. Tästä huolimatta käytännön pohdinta voi toimia ajatusten herättäjänä myös muille organisaatiolle, jotka ovat siirtymässä kohti dataohjattua päätöksentekoa kunnossapidon osa-alueella. Kunnossapidon siirtymässä on keskeistä olla takertumatta liikaa alkuperäisiin mittausasetteluihin. Saatavan palautteen ja tulosten myötä analyysien lisäksi myös analyysien lähtökohtia tulee pystyä iteroimaan, sillä niillä on merkittävä vaikutus koko lopputulokseen ja saavutettavaan liiketoiminta-arvoon. Tuotettua ratkaisua tulee tarkastella kustannusten sekä saavutettavien hyötyjen suhteessa. Tällöin on pyrittävä löytämään optimaalinen tilanne, jossa analytiikalla saadaan tavoiteltavat maksimaaliset tulokset minimaalisilla kustannuksilla.

## 7.4 Tutkimuksen arviointi ja yleistettävyyys

Tutkimuksen kirjallisuuskatsauksen osalta merkittäväksi haasteeksi muodostui aiemman vastaavan tutkimuksen puute. Lähdemateriaalin osalta merkittävää valikointia ei pystytty tekemään, sillä useammasta tässä tutkimuksessa esiintyneestä aihepiiristä oli saatavilla hyvin rajallinen määrä validia tutkimusta tai muuta kirjallisuutta. Tällöin tutkimuksen pohjana käsiteltävän tutkimuksen laatua ja relevanttiutta on erityisen haastavaa arvioida (Brocke et al. 2015). Lähdemateriaalina jouduttiin käyttämään muilla toimialoilla tai toisenlaisissa kontekstissa tehtyä tutkimusta, sillä sähköasemiin tai varsinkaan korkeajännitelaitteisiin liittyvää tutkimusta ei onnistuttu selvitystyössä löytämään. Vaikka lähteiden valikointia tehtiinkin huolellisesti, on tutkimuksessa mahdollisuus, että muilta toimialoilta tunnistetut kunnonvalvonnan tavat eivät ole yhtä lailla sovellettavissa sähköverkon kytkinlaitosten tilanteeseen. Tämän selvittäminen edellyttää lisätutkimusta. Kirjallisuuskatsauksen osalta tutkimukselle voidaan esittää kritiikkiä myös sen systemaattisuuden puutteesta. Brocke et al. (2015) esittävät tämän olevan tyypillinen ongelma kirjallisuuskatsauksille. Suoritettavat haut tuottavat usein odottamattomia tuloksia, jolloin koko kirjallisuuden hankintaprosessin suunnittelu muodostuu hankalaksi (Brocke et al. 2015).

Tutkimuksessa käytetty datan määrä oli hyvin vähäinen ja tämä johtui pitkälti tutkimusasettelusta. Tavoitteena ei ollut arvioida tunnuslukujen hyvyttä kunnonvalvonnassa, vaan tunnistaa mitä nämä tunnusluvut voisivat olla. Tästä huolimatta työssä esitellään laskennallisia tunnuslukujen lukuarvoja, jotta lukija saa kuvan, missä suuruusluokassa tunnuslukujen arvoalueet ovat ja miten ne käyttäytyvät tarkastellulle signaalille. Nämä

esimerkkitunnusluvut laskettiin joko vain yksittäisille otoksille tai vaihtoehtoisesti enintään viidelle otokselle. Otoksiko oli siis hyvin pieni ja tarkastelemalla tunnuslukujen arvoalueita voidaan tutkimuksesta tehdä virheellisiä johtopäätöksiä.

Arvioitaessa saavutettuja tuloksia on huomioitava alussa tehty tutkimusasettelu. Tehtävä tutkimus tunnistettiin alussa ensisijaiselta tieteenfilosofialtaan positivistiseksi ja tutkimusmenetelmältään tapaustutkimukseksi. Valittu tieteenfilosofia sopii hyvin tunnuslukujen tunnistukseen ja laskentaan, mutta erityisesti päätutkimuskysymyksen dataohjattuun päätöksentekoon liittyvän tutkimuskohteen tulkinnallisuus ei sovellu täysin yhteen positivistisen tieteenfilosofian kanssa. Pohdinnan osalta tutkimuksessa on myös selkeästi tieteellisen realismin piirteitä. Yleisemmällä tasolla on huomioitava, että tapaustutkimus ja positivismi eivät täysin luonnollisesti sovi ideologioiltaan yhteen. Saunders et al. (2009) kertovat, että positivismi jättää huomiotta epävarmat sekä pohdinnan tuloksena syntyneet oletukset. Tapaustutkimus puolestaan hyväksyy epävarmuuden sekä tarkastelukontekstin vaikutukset (Saunders et al. 2009). Tämän takia tästä tutkimuksesta onkin tunnistettavissa myös tieteellisen realismin tieteenfilosofian piirteitä. Tämä epäyhtenäistää kokonaisuutta, mutta tulkinnanvaraisten, pohdinnan seurauksena syntyneiden, tuloksien käsittely nähtiin kokonaisuuden ymmärtämisen kannalta tarpeelliseksi.

Tulosten arvioinnissa on otettava huomioon tutkimusmenetelmän, eli tapaustutkimuksen, aiheuttamat haasteet tutkimukselle. Tutkimusta ei tehty ulkopuolisen tarkkailijan roolissa, vaan tukea saatiin Fingridin asiantuntijoilta. Potter et al. (2010) tunnistavat tämän tapaustutkimuksen toteuttajalle haasteeksi, sillä tutkimusta voidaan ohjata organisaation tavoitteiden mukaisesti. Tässä tutkimuksessa ohjausta kerättiin tietoisesti Fingridin asiantuntijoilta, sillä kirjallisuuskatsauksessa saavutetut tulokset olivat hyvin rajalliset. Lopulta ohjauksen vaikutus koko tutkimuksen kannalta jäi hyvin vähäiseksi, sillä vain kaksi tunnuslukua, moottorin virrankäyttö sekä ohjauksen kesto, tunnistettiin asiantuntijatiedon avustuksella. Ohjauksesta on kuitenkin syytä olla tietoinen käsiteltäessä tuloksia.

Toinen tapaustutkimuksen haaste liittyy tulosten yleistettävyyteen. Tsang (2014) nostaa esille, että tapaustutkimusta kritisoidaan usein siitä, että sen tulokset ovat vähemmän yleistettäviä kuin laajojen kvantitatiivisten tutkimusten tulokset. Tapaustutkimuksen pohjalta voidaan kuitenkin tehdä yleistettäviä havaintoja, kunhan tuloksia käsitellään oikein (Tsang 2014). Tässä tutkimuksessa tehdystä tapaustutkimuksesta tehdään yleisemmän tason päätelmiä, joita lukiessa on otettava huomioon tarkastelukonteksti. Johtopäätöksiä antaessa on korostettu tarkastelun aiheuttamia vaikutuksia tulosten yleistettävyyteen.

Tutkimuksen tulosten yleistettävyyden osalta on huomioitava, että alatutkimuskysymykset ja tätä myötä osa saavutetuista tuloksista on voimakkaasti keskittynyt Fingridin tilanteeseen. Tämä ei kuitenkaan tarkoita, etteikö tutkimusta voida hyödyntää vastaavassa kontekstissa esimerkiksi toisen sähköverkkotoimijan kunnossapidon kehityksessä. Vaikka lähtökohtana toiminut mittaustilanne onkin yksilöllinen, ovat tunnusluvut ja nii-

den laskentaan käytettävät menetelmät yleispäteviä ja täten vietävissä myös toisiin konteksteihin. Mietittäessä tarkemmin tunnuslukujen tarkastelukohteita, on kyseessä perinteisiä mekaanisia komponentteja eli moottori, vaihteisto ja iskunvaimennin. Tämän takia tulosten yleistettävyydessä ei ole tarpeen rajautua pelkästään sähkölaitosten laitteisiin, vaan vastaavia mittauksia ja laskelmia voidaan suorittaa myös muille mekaanisille laitteistoille, joissa käytetään edellä mainittuja komponentteja. Tutkimuksen tulokset voivat siis tarjota pohjaa myös erityyppisille IoT-perustaisille värähtely- tai virtasignaaliin pohjautuville laitteistojen kunnonvalvonnoille.

Erityisesti alatutkimuskysymysten kohdalla tarkastellaan hyvin rajatusti Fingridin tilannetta, jolloin haasteet liittyvät käytettyyn lähdemateriaaliin. Pää tutkimuskysymyksessä tarkastelua laajennetaan lisäksi yleisemmälle tasolle, jolloin on tarkemmin arvioitava myös tapaustutkimuksen vaikutuksia tuloksiin. Huomioidessa yllä esitetyt rajoitukset ja tulosten luotettavuuteen vaikuttavat tekijät, tutkimuksessa saavutettuja tuloksia voidaan pitää luotettavina.

## 7.5 Jatkotutkimuskohteet

Työssä esitetty tutkimus avaa runsaasti jatkotutkimuskohteita, sillä selvitystyö liittyen kytkinlaitteiden kunnossapitoon IoT-analytiikan avulla on vasta alkutaipaleella. Selkeimmät jatkotutkimuskohteet jatkavat tutkimuksessa saavutettujen tulosten viemistä kohti kokonaisvaltaista IoT-analytiikkaratkaisua kunnossapidon tueksi. Tutkimuksessa ei otettu kantaa tunnuslukujen hyvyyteen laitteen kunnonvalvonnassa, vaan tunnistettiin ja laskettiin mahdollisia komponenttien kuntoa kuvaavia parametreja Kymin mittausasettelusta. Määritettyjen tunnuslukujen testaaminen suhteessa laitteiden kuntoon mahdollistaisi aidosti relevanttien tunnuslukujen sekä näiden arvoalueiden määrittämisen. Tähän liittyen olisi syytä kerätä dataa vikaantuneesta laitteesta, jotta vikatilanteen näkyminen tunnusluvussa saataisiin määritettyä. Jatkotutkimuskohde on työläs, sillä se vaatii merkittäviä mittausasetteluja, mutta siitä saatava informaatio olisi hankkeen kannalta erityisen arvokasta. Pidemmälle vietynä jatkotutkimuskohteena voidaan tunnistaa erilaisten kuntoa arvioivien mallien kehitys ja testaaminen. Tähän liittyvät esimerkiksi relevanteimpien anturointien tunnistaminen ja parhaimman ennustetarkkuuden antavien algoritmien kehitys.

Omana tutkimuskohteenaan voidaan nähdä fyysisten antureiden asennus kytkinasemille, ja näiltä saatavan datan vertailukelpoisuuden tutkiminen. Sensorien asennuksiin on syytä luoda standardit, jotta anturien asennukset eivät aiheuta merkittäviä eroja itse kerättävään dataan. Jatkotutkimuskohteeseen liittyy olennaisesti myös analyysijä edeltävän luokittelun määrittäminen. Tällä hetkellä ei vielä tiedetä voidaanko samojen kytkinlaitetyyppien tunnuslukuja verrata kytkinlaitteiden laitevalmistajien, anturien valmistajien tai kytkinasemien sijaintien välillä. Lisäksi esimerkiksi kytkinlaitteen elinkaaren vaiheen luokittelu optimaalisen ennusteen saavuttamiseksi edellyttää lisätutkimusta.

Tutkimuksen tekniseltä puolelta löytyy myös useita jatkotutkimuskohteita. Työssä ei otettu kantaa tiedostojen oikeellisuuden tunnistamiseen, mutta tämä ei tarkoita, etteikö pilvipalvelussa olisi tallennettuna virheellisiä tiedostoja. Esimerkiksi mikrofonit aktivoivat tietyn ääneen liittyvän raja-arvon ylittyessä, jonka seurauksena esimerkiksi luonnonilmiö, kuten salama, saattaa käynnistää mittauksen. Nämä voivat aiheuttaa virheellisiä päätelmiä tarkasteltaessa pelkkiä tunnuslukuja, joten yhtenä jatkotutkimuskohteena voidaan tunnistaa mitattavien tiedostojen luokittelu todellisiksi ja virheellisiksi mittauksiksi. Toisena teknisempänä jatkotutkimuskohteena voidaan nähdä laskennoissa käytettävien parametrien tutkiminen tunnuslukujen tarkkuuden parantamisen kannalta. Tällaisia parametreja ovat esimerkiksi ikkunoinnissa käytettävät ikkunan pituudet ja limittäisten datapisteiden lukumäärä, tai vaihtoehtoisesti esimerkiksi sen määrittäminen, mitä osaa äänitiedosta tietyn tunnusluvun laskentaan kuuluu käyttää.

Tarkasteltaessa kunnossapitomallin muutokseen liittyvää kokonais kuvaa voidaan tunnistaa tunnuslukujen hyödyntämiseen ja tulosten käytäntöön viemiseen liittyviä jatkotutkimuskohteita. Tutkimuksessa tunnistetut tunnusluvut eivät vielä lukuarvoina kerro tulkit-sijalle miten tulisi toimia. Jatkotutkimuskohteena olisikin hyödyllistä selvittää, miten analytiikkaratkaisun loppukäyttäjät haluavat tunnusluvut tulkittavaksi ja miten merkittävä osuus päätöksenteosta jää edelleen ihmisen vastuulle. Tästä on olennaista tunnistaa yhteys työssä esitettyihin Davenportin (2014) analytiikan tasoihin ja määrittää tavoittelevatko loppukäyttäjät ennustavaa vai ohjaavaa analytiikkaa. Tunnuslukujen tulkintatavan lisäksi jatkotutkimuskohteena tunnistetaan kunnossapitomallin siirtymään liittyvä muutosjohtaminen. Muutosjohtamisen osalta on selvitettävä, miten IoT-pohjaisen datan hyödyntäminen tulee implementoida osaksi olemassa olevia kunnossapidon prosesseja, ja miten tämän avulla mahdollistetaan siirtymä dataohjattuun päätöksentekoon.

Yleisempänä jatkotutkimusteemana voidaan nähdä sähköasemien kytkinlaitteiden kunnonvalvonnan tutkimuksen lisääminen ja syventäminen. Tehdyssä kirjallisuusselvityksessä huomattiin, että tutkimusta on saatavilla hyvin rajallinen määrä erityisesti suurjänniteverkkoihin liittyen. IoT:n ja analytiikan yleistyessä ennustava kunnossapito tulee todennäköisesti harkintaan useiden valtioiden kantaverkkotoimijoille. Erityisesti edullisiin jälkikäteen asennettaviin anturointeihin keskittävälle tutkimukselle on tarvetta.

## LÄHTEET

- Alastalo, R., Bärling, M., Hirvonen, M., Hyppönen, H., Issakainen, O., Packalén, E., Saarinen, L., & Väyrynen, P. (n.d.) Kunnossapito - menestystekijä. Opetushallitus, Edu.fi, Kunnossapitoyhdistys ry.
- Andrienko, N., Lammarsch, T., Andrienko, G., Fuchs, G., Keim, D., Miksch, S., & Rind, A. (2018.) Viewing Visual Analytics as Model Building. *Computer Graphics Forum*, vol. 37, no. 6, pp. 275–299.
- Aro, M., Elovaara, J., Karttunen, M., Nousiainen, K., & Palva, V. (2015.) Suurjännite-tekniikka, 4. korj. ja täydennetty p. Helsinki: Otatieto. p. 537.
- Badía, F.G., Berrade, M.D., & Campos, C.A. (2002.) Optimal inspection and preventive maintenance of units with revealed and unrevealed failures. *Reliability Engineering & System Safety*, vol. 78, no. 2, pp. 157–163.
- Barbera, F., Schneider, H., & Kelle, P. (1996.) A Condition Based Maintenance Model with Exponential Failures and Fixed Inspection Intervals. *The Journal of the Operational Research Society*, vol. 47, no. 8, pp. 1037–1045.
- Beed, M., van Bennekum, A., Cockburn, A., Cunningham, W., Fowler, M., Highsmith, J., Hunt, A., Jeffries, R., Kern, J., Marick, B., Martin, R., Schwaber, K., Sutherland, J., & Thomas, D. (2001.) Manifesto for Agile Software Development. Available from: <http://agilemanifesto.org/>. (Retrieved 4 September 2018).
- Benbasat, I., Goldstein, D.K., & Mead, M. (1987.) The Case Research Strategy in Studies of Information Systems. *MIS Quarterly*, vol. 11, no. 3, p. 369.
- Benkedjouh, T., Zerhouni, N., & Rechak, S. (2017.) Tool condition monitoring based on mel-frequency cepstral coefficients and support vector regression. 2017 5th International Conference on Electrical Engineering - Boumerdes (ICEE-B), pp. 1–5.
- Bosnjak, Z., Grljevic, O., & Bosnjak, S. (2009.) CRISP-DM as a framework for discovering knowledge in small and medium sized enterprises' data. 2009 5th International Symposium on Applied Computational Intelligence and Informatics, pp. 509–514.
- Brocke, J.V., Simons, A., Riemer, K., Niehaves, B., & Plattfaut, R. (2015.) Standing on the Shoulders of Giants: Challenges and Recommendations of Literature Search in Information Systems Research. *Communications of the Association for Information Systems*, vol. 37, no. 9, p. 22.
- Brodersson, A.L., Jürgensen, J.H., & Hilber, P. (2016.) Towards health assessment: Failure analysis and recommendation of condition monitoring techniques for large disconnector populations, CIREN Workshop 2016, pp. 1–4.
- Bryman, A. (2012.) *Social Research Methods*, 4th edn. OUP Oxford, New York. p. 808.

Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000.) CRISP-DM 1.0 - Step-by-step data mining guide. SPSS Inc., p. 76.

Cho, Y.T. (2018.) Characterizing Sources of Small DC Motor Noise and Vibration. *Micromachines*; Basel, vol. 9, no. 2, p. 84.

Collis, J. & Hussey, R. (2003.) *Business Research - A Practical Guide for Undergraduate and Postgraduate Students*, 4th edn. Red Globe Press. p. 376.

Dadashi, N., Wilson, J.R., Golightly, D., & Sharples, S. (2014.) A framework to support human factors of automation in railway intelligent infrastructure. *Ergonomics*, vol. 57, no. 3, pp. 387–402.

Davenport, T.H. (2014.) *Business Analytics Defined*. Video. Available from: <https://hbr.org/video/2386816175001/business-analytics-defined>. (Retrieved 20 October 2018).

Davenport, T.H. (2016.) Five types of analytics of things - Data crunching that goes beyond business intelligence. *Deloitte Insights*. Available from: <https://www2.deloitte.com/insights/us/en/topics/analytics/five-types-of-analytics-of-things.html>. (Retrieved 21 October 2018).

Davenport, T.H. & Patil, D.J. (2012.) Data Scientist: The Sexiest Job of the 21st Century. *Harvard Business Review*. October 2012. Available from: <https://hbr.org/2012/10/data-scientist-the-sexiest-job-of-the-21st-century>. (Retrieved 20 October 2018).

Decker, H.J. (2002.) Crack Detection for Aerospace Quality Spur Gears. *International 58th Annual Forum and Technology Display*; 11-13 Jun. 2002; Montreal, Quebec; Canada.

Delen, D. & Demirkan, H. (2013.) Data, information and analytics as services. *Decision Support Systems*, vol. 55, no. 1, pp. 359–363.

Dou, L., Wan, S., & Zhan, C. (2018.) Application of Multiscale Entropy in Mechanical Fault Diagnosis of High Voltage Circuit Breaker. *Entropy*; Basel, vol. 20, no. 5, p. 325.

Dupraz, J.P., Luescher, R., & Montillet, G.F. (2006.) A hybrid drive merging a servo-controlled motor and a spring mechanism. *IEEE Transactions on Power Delivery*, vol. 21, no. 2, pp. 640–645.

Elovaara, J. & Haarla, L. (2011.) *Sähköverkot 2: verkon suunnittelu, järjestelmät ja laitteet*. Otatieto, Helsinki. p. 551.

Fernandez, D.J. & Fernandez, J.D. (2008.) Agile Project Management - Agilism Versus Traditional Approaches. *The Journal of Computer Information Systems*; Stillwater, vol. 49, no. 2, pp. 10–17.

Fingrid Oyj (n.d.) Kehityshankkeet. Saatavilla: <https://www.fingrid.fi/sahkomarkkinat/sahkomarkkinoiden-tulevaisuus/kehityshankkeet/>. (Luettu 15 elokuuta 2018).

Fingrid Oyj (2011.) *Kantaverkon käsikirja*. Fingrid Oyj, Helsinki.

Fingrid Oyj (2018a.) Kuluttajatietoa. Saatavilla: <https://www.fingrid.fi/palvelut/fingridin-asiakkaat/kuluttajatietoa/>. (Luettu 15 elokuuta 2018).

Fingrid Oyj (2018b.) Fingrid vuosikertomus 2017. Saatavilla: <https://annualreport.fingrid.fi/>. (Luettu 15 elokuuta 2018).

Gartner (n.d.) Diagnostic Analytics. Gartner IT Glossary. Available from: <https://www.gartner.com/it-glossary/diagnostic-analytics/>. (Retrieved 21 October 2018).

Głowacz, A. (2016.) Fault diagnostics of DC motor using acoustic signals and MSAF-RATIO30-EXPANDED. Archives of Electrical Engineering; Warsaw, vol. 65, no. 4, pp. 733–744.

Głowacz, A. & Głowacz, Z. (2017.) Recognition of rotor damages in a DC motor using acoustic signals. Polska Akademia Nauk. Bulletin of the Polish Academy of Sciences: Technical Sciences; Warsaw, vol. 65, no. 2, pp. 187–194.

Golightly, D., Kefalidou, G., & Sharples, S. (2017.) A cross-sector analysis of human and organisational factors in the deployment of data-driven predictive maintenance. Information Systems and e-Business Management, pp. 1–22.

Grady, N.W., Payne, J.A., & Parker, H. (2017.) Agile big data analytics: AnalyticsOps for data science. 2017 IEEE International Conference on Big Data (Big Data), 2017 IEEE International Conference on Big Data (Big Data), pp. 2331–2339.

Gubbi, J., Buyya, R., Marusic, S., & Palaniswami, M. (2013.) Internet of Things (IoT): A vision, architectural elements, and future directions. Future Generation Computer Systems, vol. 29, no. 7, pp. 1645–1660.

Haarla, L. & Elovaara, J. (2011.) Sähköverkot 1: Järjestelmäteknikka ja sähköverkon laskenta. Gaudeamus Helsinki University Press / Otatieto. p. 520.

Hatakka, S., Pietilä, T., & Huurinainen, V. (2013.) Voimajohtotyömaalla kuolemaan joutanut sähkötyötapaturma Savitaipaleella 17.4.2013. Turvallisuus- ja kemikaalivirasto, Helsinki. Saatavilla: [https://tukes.fi/documents/10197/8647605/savitaipale\\_onnettomuustutkintaraportti\\_valmis.pdf](https://tukes.fi/documents/10197/8647605/savitaipale_onnettomuustutkintaraportti_valmis.pdf). (Luettu 24 heinäkuuta 2018).

Heininen, A., Aaltonen, J., Koskinen, K., & Huitula, J. (2016.) Improving Condition Monitoring Methods for a Fighter Aircraft Main Landing Gear Shock Absorber. Annual SMACC Research Seminar, pp. 65–69.

IEEE-SA Standards Board (1996.) IEEE Guide for Diagnostics and Failure Investigation of Power Circuit Breakers. Reaffirmed 2008. IEEE Std C37.10-1995.

International Telecommunication Union (2012.) Overview of the Internet of things - Next Generation Networks – Frameworks and functional architecture models. Telecommunication Standardization Sector of ITU. ITU-T Y.2060. p. 22.

Iorgulescu, M. & Beloiu, R. (2012.) Study of DC motor diagnosis based on the vibration spectrum and current analysis. 2012 International Conference on Applied and Theoretical Electricity (ICATE), pp. 1–4.



Janssen, A., Makareinis, D., & Sölver, C.E. (2014.) International Surveys on Circuit-Breaker Reliability Data for Substation and System Studies. *IEEE Transactions on Power Delivery*, vol. 29, no. 2, pp. 808–814.

Janssen, A.L.J., Degen, W., Heising, C., Bruvik, H., Colombo, E., Lanz, W., Fletcher, P., & Sanchis, G. (1994.) Final report of the 2nd international enquiry on HV circuit-breaker failures and defects in service. Cigre, Paris. Available from: <https://e-cigre.org/publication/083-final-report-of-the-2nd-international-enquiry-on-hv-circuit-breaker-failures-and-defects-in-service>. (Retrieved 25 July 2018).

Järviö, J., Piispa, T., Parantainen, T., & Åström, T. (2007.) Kunnossapito, 4. uud. p. KP-Media, Helsinki.

Kefalidou, G., Golightly, D., & Sharples, S. (2015.) Understanding Factors for Design and Deployment of Predictive Maintenance, Fifth International Rail Human Factors Conference. London, UK.

Keim, D.A., Mansmann, F., Schneidewind, J., & Ziegler, H. (2006.) Challenges in Visual Data Analysis, Tenth International Conference on Information Visualisation, pp. 9–16.

Keogh, E.J. & Pazzani, M.J. (1999.) Scaling up Dynamic Time Warping to Massive Datasets JM Żytkow & J Rauch (eds). *Principles of Data Mining and Knowledge Discovery*, pp. 1–11. Springer, Berlin, Heidelberg.

Kohlhammer, J., Keim, D., Pohl, M., Santucci, G., & Andrienko, G. (2011.) Solving Problems with Visual Analytics. *Procedia Computer Science*, vol. 7, pp. 117–120.

Koochaki, J. & Bouwhuis, I.M. (2008.) The role of knowledge sharing and Transactive Memory System on Condition Based Maintenance policy, 2008 IEEE International Conference on Industrial Engineering and Engineering Management, pp. 32–36.

Kothamasu, R., Huang, S.H., & VerDuin, W.H. (2006.) System health monitoring and prognostics — a review of current paradigms and practices. *The International Journal of Advanced Manufacturing Technology*, vol. 28, no. 9–10, pp. 1012–1024.

Kranz, M. (2017.) Building The Internet of Things: Bringing IoT Into Your Organization - Change Management (Part 4). Advantage Business Media. Trade Journals. Manufacturing.net; Rockaway.

Kuosa, D. (2007.) Vika- ja kunnossapitotietojen hyödyntäminen suurjännitekytkinlaitteiden kunnonhallinnassa. Diplomityö. Sähkö- ja tietoliikennetekniikan osasto, Teknillinen korkeakoulu, Helsinki. p. 102.

Laitinen, T., Lyly, T., Stenstrand, M., Tammi, J., Albrecht, R., Nyberg, J., & Saksela, K. (2018.) Wireless sensor units for acoustic monitoring of switching devices. *CIGRE 2018*, p. 10.

Laitinen, T. & Tammi, J. (2018.) Diplomityötä varten käydyt teema- ja palautekeskustelut liittyen Fingridin kytkinlaitteisiin ja IoT anturointiin. Fingrid Oyj, Helsinki.

Lakervi, E. & Partanen, J. (2008.) *Sähkönjakelutekniikka*, 1st edn. Gaudeamus Helsinki University Press / Otatieto, Helsinki.

- Larson, D. & Chang, V. (2016.) A review and future direction of agile, business intelligence, analytics and data science. *International Journal of Information Management*, vol. 36, no. 5, pp. 700–710.
- Lau, E.C.C. & Ngan, H.W. (2010.) Detection of Motor Bearing Outer Raceway Defect by Wavelet Packet Transformed Motor Current Signature Analysis. *IEEE Transactions on Instrumentation and Measurement*, vol. 59, no. 10, pp. 2683–2690.
- Lebold, M., McClintic, K., Cambell, R., Byington, C., & Maynard, K. (2000.) Review of Vibration Analysis Methods for Gearbox Diagnostics and Prognostics. *Proceedings of the 54th Meeting of the Society for Machinery Failure Prevention Technology*, pp. 623–634.
- Lee, J., Wang, H., Kobbacy, K., & Murthy, D.N. (2008.) Chapter 3: New Technologies for Maintenance. In: *Complex System Maintenance Handbook*, pp. 49–78. Springer-Verlag London.
- Li, Z., Yan, X., Yuan, C., Peng, Z., & Li, L. (2011.) Virtual prototype and experimental research on gear multi-fault diagnosis using wavelet-autoregressive model and principal component analysis method. *Mechanical Systems and Signal Processing*, vol. 25, no. 7, pp. 2589–2607.
- Lindquist, T.M., Bertling, L., & Eriksson, R. (2008.) Circuit breaker failure data and reliability modelling. *Transmission Distribution IET Generation*, vol. 2, no. 6, pp. 813–820.
- Marr, B. (2017.) Data-Driven Decision Making: Beware Of The HIPPO Effect! *Forbes - Data-driven Decision making*. Available from: <https://www.forbes.com/sites/bernard-marr/2017/10/26/data-driven-decision-making-beware-of-the-hippo-effect/#1f779e4c80f9>. (Retrieved 20 October 2018).
- Mazza, G. & Michara, R. (1981.) The first international enquiry on circuit-breaker failures and defects in service. *Cigre*. Available from: [https://e-cigre.org/publication/ELT\\_079\\_1-the-first-international-enquiry-on-circuit-breaker-failures-and-defects-in-service](https://e-cigre.org/publication/ELT_079_1-the-first-international-enquiry-on-circuit-breaker-failures-and-defects-in-service). (Retrieved 25 July 2018).
- McAfee, A. & Brynjolfsson, E. (2012.) Big Data: The Management Revolution. *Harvard Business Review*, no. October 2012. Available from: <https://hbr.org/2012/10/big-data-the-management-revolution>. (Retrieved 19 October 2018).
- Memon, S., Lech, M., & He, L. (2009.) Using information theoretic vector quantization for inverted MFCC based speaker verification, *Control and Communication 2009 2nd International Conference on Computer*, pp. 1–5.
- Nelwamondo, F. & Marwala, T. (2006.) Faults Detection Using Gaussian Mixture Models, Mel-Frequency Cepstral Coefficients and Kurtosis, 2006 *IEEE International Conference on Systems, Man and Cybernetics*, pp. 290–295. Taipei, Taiwan.
- Nohynek, P. & Lumme, V.E. (2004.) *Kunnonvalvonnan v r htelymittaukset*, 2nd edn. KP-Media, Hamina. p. 146.

Olkkonen, T. (1994.) *Johdatus teollisuustalouden tutkimustyöhön*, 2nd edn. Teknillinen korkeakoulu, Aalto-yliopisto - Perustieteiden korkeakoulu - Tuotantotalouden laitoksen kirjasto. p. 143.

Parpala, R.C. & Iacob, R. (2017.) Application of IoT concept on predictive maintenance of industrial equipment. MATEC Web of Conferences. EDP Sciences, Les Ulis, France.

Pham, H. (1995.) *Software Reliability and Testing*, 1 edition. Wiley-IEEE Computer Society Pr, Los Alamitos, Calif. p. 144.

Pham, H., Suprasad, A., & Misra, R.B. (1997.) Availability and mean life time prediction of multistage degraded system with partial repairs. *Reliability Engineering & System Safety*, vol. 56, no. 2, pp. 169–173.

Pham, H. & Wang, H. (1996.) Imperfect maintenance. *European Journal of Operational Research*, vol. 94, no. 3, pp. 425–438.

Pintelon, L. & Parodi-Herz, A. (2008.) Chapter 3: Maintenance: An Evolutionary Perspective. In: *Complex System Maintenance Handbook*, pp. 21–48. Springer-Verlag London.

Potter, L.-E., von Hellens, L., & Nielsen, S. (2010.) The Practical Challenges of Case Study Research: Lessons from the field, 5th International Conference on Qualitative Research in IT & IT in Qualitative Research, p. 8. Brisbane.

Press, W.H., Teukolsky, S., Vetterling, W., & Flannery, B. (1992.) Chapter 14. Statistical Description of Data, Savitsky-Golay Smoothing Filters. In: *Numerical recipes in C: the art of scientific computing*, pp. 650–655. Cambridge University Press, New York.

Qiu, Z., Ruan, J., & Huang, D. (2016.) Mechanical fault diagnosis of outdoor high-voltage disconnecter. *IEEE Transactions on Electrical and Electronic Engineering*, vol. 11, no. 5, pp. 556–563.

Qiu, Z., Ruan, J., Huang, D., & Huang, Y. (2014.) Mechanical fault diagnosis of high voltage outdoor disconnecter based on motor current signal analysis, 2014 International Conference on Power System Technology, pp. 1193–1198.

Rao, B.K.N. (1998.) *Handbook of Condition Monitoring - Techniques and Methodology*, 1st edn. Springer Netherlands. p. 565.

Razi-Kazemi, A.A., Vakilian, M., Niayesh, K., & Lehtonen, M. (2014.) Circuit-Breaker Automated Failure Tracking Based on Coil Current Signature. *IEEE Transactions on Power Delivery*, vol. 29, no. 1, pp. 283–290.

Roininen, T., Sölver, C.E., Nordli, H., Bosma, A., Jonsson, P., & Alfredsson, A. (2013.) *Live Tank Circuit Breakers, Application Guide*. High Voltage Products. ABB AB. Available from: <http://www.abb.com/abblibrary/DownloadCenter/>. (Retrieved 13 July 2018).

Rubhini, B. & Ranjan, P.V. (2017.) Machine condition monitoring using audio signature analysis, 2017 Fourth International Conference on Signal Processing, Communication and Networking (ICSCN), pp. 1–6.

Runde, M. (2013.) Failure Frequencies for High-Voltage Circuit Breakers, Disconnectors, Earthing Switches, Instrument Transformers, and Gas-Insulated Switchgear. *IEEE Transactions on Power Delivery*, vol. 28, no. 1, pp. 529–530.

Runde, M., Sölver, C.E., Carvalho, A., Cormenzana, M.L., Furuta, H., Makareinis, D., Martins, J.F., Mestrovic, K., Ohno, I., Östlund, J., Park, K.-Y., Patel, J., Protze, C., Schmid, J., Skog, J.E., Sweeney, B., & Waite, F. (2012.) Final Report of the 2004 - 2007 International Enquiry on Reliability of High Voltage Equipment - Part 3 - Disconnectors and Earthing Switches. Available from: <https://e-cigre.org/publication/510-final-report-of-the-2004---2007-international-enquiry-on-reliability-of-high-voltage-equipment---part-2-sf6-circuit-breakers>. (Retrieved 26 July 2018).

Runeson, P. & Höst, M. (2009.) Guidelines for conducting and reporting case study research in software engineering. *Empirical Software Engineering*, vol. 14, no. 2, pp. 131–164.

Saaranen-Kauppinen, A., Puusniekka, A., Kuula, A., Rissanen, R., & Karvinen, I. (2009.) Menetelmäopetuksen tietovaranto KvaliMOTV - Kvalitatiivisten menetelmien verkkopikirja, 2nd edn. Yhteiskuntatieteellinen tietoaarkisto Tampereen yliopisto, Tampere. p. 170. Saatavilla: <http://www.fsd.uta.fi/menetelmaopetus/>. (Luettu 15 heinäkuuta 2018).

Sait, A. & Sharaf-Eldeen, Y. (2011.) A Review of Gearbox Condition Monitoring Based on vibration Analysis Techniques Diagnostics and Prognostics. *Conference Proceedings of the Society for Experimental Mechanics Series*, pp. 307–324.

Satuli, H. (2018.) Energiamurros haastaa kantaverkon – pelissä on Suomen kilpailukyky. FINGRID-lehti. Saatavilla: <https://www.fingridlehti.fi/pelissa-suomen-kilpailukyky/>. (Luettu 3 heinäkuuta 2018).

Saunders, M.N.K., Lewis, P., & Thornhill, A. (2009.) Research methods for business students, 5th ed. Prentice Hall, New York. p. 614.

Schrage, M. (2016.) How the Big Data Explosion Has Changed Decision Making. *Harvard Business Review*. Available from: <https://hbr.org/2016/08/how-the-big-data-explosion-has-changed-decision-making>. (Retrieved 19 October 2018).

Schuller, B. (2013.) Intelligent Audio Analysis. *Signals and Communication Technology*, 1st edn. Springer-Verlag Berlin Heidelberg. p. 345.

Serrador, P. & Pinto, J.K. (2015.) Does Agile work? — A quantitative analysis of agile project success. *International Journal of Project Management*, vol. 33, no. 5, pp. 1040–1051.

SFS EN-13306 (2010.) Kunnossapito, Kunnossapidon terminologia. CEN/TC 219 Maintenance.

Shearer, C. (2000.) The CRISP-DM Model: The New Blueprint for Data Mining. *Journal of Data Warehousing*, vol. 2000, no. Vol. 5. Num. 4, p. 10.

Shneiderman, B. (1996.) The eyes have it: a task by data type taxonomy for information visualizations, *Proceedings 1996 IEEE Symposium on Visual Languages*, pp. 336–343.

Siemens (2018.) Disconnectors and earthing switches. Siemens - Ingenuity for life. Available from: <https://www.siemens.com/global/en/home/products/energy/high-voltage/hv-switchgear/disconnectors-earthing-switches.html>. (Retrieved 24 July 2018).

Sihvonen-Punkka, A. (2018.) Hyvin toimivat sähkömarkkinat tarvitsevat vahvan sähköverkon. FINGRID-lehti. Saatavilla: <https://www.fingridlehti.fi/toimivat-sahkomarkkinat/>. (Luettu 3 heinäkuuta 2018).

Tammi, J. (2018.) Kunnonhallinnan IoT -ratkaisut. Omaisuuden hallinnan ajankohtaisseminaari 23.5.2018. Saatavilla: <https://www.epressi.com/media/userfiles/103273/1527148975/omaisuuden-hallinnan-ajankohtaisseminaarin-esitykset.pdf>. (Luettu 28 heinäkuuta 2018).

Thomas, J.J. & Cook, K.A. (2005.) Illuminating the Path: The Research and Development Agenda for Visual Analytics. National Visualization and Analytics Center. United States, Department of Homeland Security. Available from: <https://www.hSDL.org/?view&did=485291>. (Retrieved 16 August 2018).

Tsang, E.W.K. (2014.) Generalizing from Research Findings: The Merits of Case Studies. *International Journal of Management Reviews*, vol. 16, no. 4, pp. 369–383.

Tzanetakis, G. & Cook, P. (2002.) Musical genre classification of audio signals. *IEEE Transactions on Speech and Audio Processing*, vol. 10, no. 5, pp. 293–302.

Vanraj, Dhani, S.S., & Pabla, B.S. (2017.) Optimization of sound sensor placement for condition monitoring of fixed-axis gearbox. *Cogent Engineering*, vol. 4, no. 1, p. 24.

Večeř, P., Kreidl, M., & Šmíd, R. (2005.) Condition Indicators for Gearbox Condition Monitoring Systems. *Acta Polytechnica*, vol. 45, no. 6, p. 9.

Wang, H. (2002.) A survey of maintenance policies of deteriorating systems. *European Journal of Operational Research*, vol. 139, no. 3, pp. 469–489.

Wang, Z., Zhang, J., & Liang, Y. (2013.) Motor Noise and Vibration Test Research. *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, vol. 11, no. 1, pp. 87–94.

Wenning, C.J. (2009.) Scientific epistemology: How scientists know what they know. *Journal of Physics Teacher Education Online*, vol. 5, no. 2, p. 13.

Wong, P.C. & Thomas, J. (2004.) Visual Analytics. *IEEE Computer Graphics and Applications*, vol. 24, no. 5, pp. 20–21.

Yin, R.K. (2003.) Case Study Research: Design and Methods. *Applied Social Research Methods Series*, Vol. 5. SAGE Publications. p. 204.

Young, H.D. & Freedman, R.A. (2003.) *Sears and Zemansky's university physics : with modern physics*, 11th ed. Pearson Addison-Wesley, San Francisco, CA. p. 1714.